


به همراه CD

مقدماتی

اقتصادسنجی (جلد ۱)

همراه با کاربرد Eviews8 & Stata 12



دکتر علی سوری

فهرست مطالب

صفحه	عنوان
	مقدمه
۱	فصل اول: مروری بر مفاهیم پایه‌ای آمار و نرم‌افزارهای Stata و Eviews
۵	۱-۱ مقدمه
۵	۱-۲ نمونه تصادفی
۶	۱-۳ توزیع مشترک متغیرهای نمونه با توزیع مشترک نمونه تصادفی
۸	۱-۴ تابعی از متغیرهای نمونه (آماره)
۹	۱-۵ تخمین
۹	۱-۵-۱ تخمین و تخمین‌زننده
۱۱	۱-۵-۲ روش‌های تخمین
۱۱	روش گشتاورها
۱۲	روش حداکثر درستنمایی
۱۴	روش حداقل مربعات معمولی
۱۴	۱-۵-۳ خواص تخمین‌زننده‌ها
۱۵	بدون تورش یا ناریب بودن
۱۶	کارایی (حداقل واریانس)
۱۸	سازگاری
۱۹	کفایت
۲۱	۱-۵-۴ تخمین فاصله‌ای
۲۳	۱-۶ آزمون فرضیه
۲۴	خطای نوع اول و نوع دوم
۲۵	۱-۷ مروری بر توزیع‌های مهم
۲۵	۱-۷-۱ توزیع نرمال استاندارد

۲۵	۱-۷-۲ توزیع کای دو
۲۸	۱-۷-۳ توزیع t
۲۹	۱-۷-۴ توزیع F
۳۰	۱-۷-۵ حالت‌های خاص توزیم‌های χ^2 ، t و F
۳۱	۱-۸ انواع داده‌ها
۳۲	۱-۹ آشنایی مقدماتی با نرم افزار Eviews
۳۹	مسائل
۴۲	ضمیمه فصل اول: مروری بر نرم افزار Stata
۵۳	فصل دوم: رگرسیون ساده
۵۳	۲-۱ مقدمه
۵۳	۲-۲ امید ریاضی شرطی و رگرسیون
۵۵	رگرسیون نرمال
۵۷	۲-۳ جمله خطا و معادله رگرسیون
۵۸	۲-۴ فروض معادله رگرسیون
۶۲	۲-۵ تحلیل رگرسیون تجربی
۶۳	۲-۶ تخمین معادله رگرسیون
۶۶	۲-۷ خواص تخمین‌زننده‌های OLS
۶۷	۲-۷-۱ تخمین‌زننده خطی
۶۷	۲-۷-۲ بدون تورش بودن
۶۸	۲-۷-۳ سازگاری
۶۸	۲-۷-۴ حداقل واریانس
۶۹	۲-۷-۵ توزیع تخمین‌زننده‌های OLS
۶۹	۲-۷-۶ همبستگی α و β
۷۱	۲-۸ تغییرات کل، تغییرات توضیح داده شده و تغییرات توضیح داده نشده
۷۲	۲-۹ ضریب تعیین (R^2)
۷۳	۲-۱۰ میانگین خطای تخمین یا انحراف معیار رگرسیون ($\hat{\sigma}$)
۷۵	۲-۱۱ آزمون معنادار بودن ضرایب رگرسیون
۷۷	۲-۱۲ تحلیل واریانس (آزمون معنادار بودن رگرسیون)
۸۰	۲-۱۳ جمع‌بندی و تحلیل نتایج رگرسیون
۸۳	۲-۱۴ پیش‌بینی و فاصله اطمینان پیش‌بینی
۸۷	۲-۱۵ رگرسیون‌های غیرخطی
۸۷	۲-۱۵-۱ روابط معکوس

۸۸	۲-۱۵-۲ معادلات تمام لگاریتمی (log-log)
۹۰	۲-۱۵-۳ توابع نمایی
۹۱	۲-۱۵-۴ رگرسیون انحراف از میانگین
۹۲	۲-۱۵-۵ رگرسیون با متغیرهای استاندارد شده
۹۳	۲-۱۵-۷ برآورد معادله روند
۹۴	۲-۱۵-۸ برآورد معادله نرخ رشد
۹۶	۲-۱۶ تحلیل همبستگی
۹۶	۲-۱۶-۱ کوواریانس
۹۹	۲-۱۶-۲ ضریب همبستگی
۱۰۴	مسائل
۱۱۰	ضمیمه فصل دوم: برآورد رگرسیون ساده در Stata
۱۱۹	فصل سوم: رگرسیون چندمتغیره
۱۱۹	۳-۱ مقدمه
۱۱۹	۳-۲ رگرسیون دو متغیره: مفاهیم و فروض
۱۲۰	۳-۳ تخمین ضرایب رگرسیون دو متغیره و خواص آنها
۱۲۳	۳-۴ ضریب تعیین و خطای معادله رگرسیون
۱۲۵	۳-۵ معیارهای اطلاعات
۱۲۶	۳-۶ آزمون معنی دار بودن ضرایب معادله رگرسیون
۱۲۷	۳-۷ آزمون معنی دار بودن معادله رگرسیون (تحلیل واریانس)
۱۲۸	۳-۸ تحلیل نتایج رگرسیون دو متغیره
۱۳۰	۳-۹ تحلیل همبستگی چندمتغیره
۱۳۳	۳-۱۰ مدل K متغیره
۱۴۰	۳-۱۱ رگرسیون مقید و تخمین زنده های مقید
۱۴۳	۳-۱۲ آزمون محدودیت ها
۱۴۸	۳-۱۳ پیش بینی با رگرسیون چندمتغیره
۱۵۰	مسائل
۱۵۵	ضمیمه فصل سوم: برآورد رگرسیون چند متغیره در Stata
۱۵۹	فصل چهارم: نقض فروض کلاسیک
۱۵۹	۴-۱ مقدمه
۱۵۹	۴-۲ فرض اول: صفر بودن میانگین خطا
۱۶۳	۴-۳ فرض دوم: واریانس همسانی

۱۶۳	۴-۳-۱ ماهیت واریانس ناهمسانی
۱۶۵	۴-۳-۲ پیامدهای واریانس ناهمسانی
۱۶۵	۴-۳-۳ برآورد واریانس مستحکم وایت
۱۶۹	۴-۳-۴ آزمون‌های تشخیص واریانس ناهمسانی
۱۶۹	الف) آزمون بارتلت
۱۷۱	ب) آزمون گلدفلد-کوانت
۱۷۲	ج) آزمون گلجسر
۱۷۲	د) آزمون همبستگی رتبه‌ای اسپیرمن
۱۷۳	هـ) آزمون بروش-پاگان-گادفری
۱۷۴	و) آزمون هاروی
۱۷۵	ز) آزمون وایت
۱۷۹	۴-۳-۵ تخمین ضرایب با وجود واریانس ناهمسانی
۱۸۵	۴-۴ فرض سوم: عدم خودهمبستگی
۱۸۵	۴-۴-۱ مفهوم وقفه
۱۸۵	۴-۴-۱ پیامدهای خودهمبستگی
۱۸۶	۴-۴-۲ روش‌های نموداری جهت تشخیص خودهمبستگی
۱۹۰	۴-۴-۳ آزمون دوربین-واتسون
۱۹۴	۴-۴-۴ آزمون بروش-گادفری
۱۹۶	۴-۴-۵ پیامد نادیده گرفتن خودهمبستگی
۱۹۷	۴-۴-۶ تخمین ضرایب در حالت خودهمبستگی
۱۹۹	۴-۴-۷ خودهمبستگی و مدل‌های پویا
۲۰۲	۴-۴-۸ خودهمبستگی و فرایندهای خودرگرسیون (AR) و میانگین متحرک
۲۰۳	۴-۵ فرض ۴: غیر تصادفی بودن متغیرهای توضیحی
۲۰۴	۴-۶ فرض ۵: فرض نرمال بودن u_t
۲۰۸	مسائل
۲۱۲	ضمیمه فصل چهارم: آزمون نقض فروض در Stata
۲۱۷	فصل پنجم: متغیرهای مجازی
۲۱۷	۵-۱ مقدمه
۲۱۷	۵-۲ متغیر مجازی
۲۱۸	۵-۳ رگرسیون روی متغیر مجازی
۲۲۰	۵-۴ دام متغیرهای مجازی
۲۲۱	۵-۴ رگرسیون روی متغیر مجازی همراه با متغیر توضیحی

۲۲۱	۵-۵ متغیر مجازی و تغییر شیب
۲۲۳	۵-۶ وجود دو عامل کیفی
۲۲۴	۵-۷ تأثیر متقابل دو عامل کیفی
۲۲۴	۵-۸ متغیرهای مجازی و تغییر ساختار
۲۲۵	۵-۹ متغیرهای مجازی و مشاهدات دور افتاده
۲۲۸	۵-۱۰ متغیرهای مجازی و تغییرات فصلی
۲۲۹	۵-۱۱ توابع لگاریتمی و متغیر مجازی
۲۳۰	۵-۱۲ قیمت گذاری عوامل کیفی
۲۳۲	مسائل
۲۳۴	ضمیمه فصل پنجم: متغیرهای مجازی در Stata
۲۳۷	فصل ششم: آزمون‌های خاص: تصریح مدل، تغییر ساختاری و علّیت
۲۳۷	۶-۱ مقدمه
۲۳۷	۶-۲ همخطی
۲۳۷	۶-۲-۱ مفهوم همخطی
۲۳۸	۶-۲-۲ مشکلات ناشی از همخطی
۲۳۹	۶-۲-۳ شناسایی همخطی
۲۴۲	۶-۲-۴ راه‌های کاهش همخطی
۲۴۴	۶-۳ فرم تابعی نادرست
۲۴۸	۶-۴ حذف متغیرهای مهم
۲۵۳	۶-۵ ورود متغیرهای نامربوط
۲۵۶	۶-۶ آزمون‌های ثبات ضرایب
۲۵۶	۶-۶-۱ آزمون نقطه شکست چاو
۲۵۸	۶-۶-۲ آزمون پیش‌بینی چاو
۲۶۰	۶-۶-۳ آزمون‌های بازگشتی
۲۶۴	۶-۶-۴ پیش‌بینی یک‌قدمی
۲۶۶	۶-۶-۵ آزمون مجموع تجمعی خطاهای بازگشتی (CUSUM)
۲۶۸	۶-۶-۶ آزمون مجموع مجذور تجمعی خطاهای بازگشتی (CUSUMQ)
۲۶۹	۶-۶-۷ متغیرهای مجازی
۲۷۰	۶-۷ خطای اندازه‌گیری متغیرها
۲۷۳	۶-۹ علّیت
۲۷۵	مسائل
۲۷۸	ضمیمه فصل ششم: آزمون‌های خاص در Stata

جلد دوم

۲۸۳	فصل هفتم: روش حداکثر درستنمایی
۲۸۳	۷-۱ مقدمه
۲۸۳	۷-۲ تابع درستنمایی
۲۸۵	۷-۳ تخمین‌زننده حداکثر درستنمایی
۲۸۶	۷-۴ روش حداکثر درستنمایی در رگرسیون ساده
۲۸۸	۷-۵ روش حداکثر درستنمایی در رگرسیون چند متغیره
۲۹۰	۷-۶ روش حداکثر درستنمایی در حالت واریانس ناهمسانی (روش GLS)
۲۹۲	۷-۶ شبیه R^2
۲۹۳	۷-۷ آزمون معنی‌دار بودن رگرسیون
۲۹۴	۷-۸ تخمین‌زننده حداکثر درستنمایی مقید
۲۹۵	۷-۹ شرط مرتبه دوم
۲۹۶	۷-۱۰ ماتریس امتیاز
۲۹۹	۷-۱۱ ماتریس اطلاعات
۳۰۰	۷-۱۲ رابطه ماتریس امتیاز و ماتریس اطلاعات
۳۰۲	۷-۱۳ نامساوی کرامر-رائو
۳۰۴	۷-۱۴ آزمون نسبت درستنمایی (LR)
۳۰۶	۷-۱۵ آزمون ضریب لاگرانژ
۳۰۸	۷-۱۶ آزمون والد
۳۱۰	۷-۱۷ مقایسه آماره‌های نسبت درستنمایی، والد و ضریب لاگرانژ
۳۱۳	مسائل
۳۱۵	فصل هشتم: متغیرهای ابزاری (IV) و حداقل مربعات دومرحله‌ای (2SLS)
۳۱۵	۸-۱ مقدمه
۳۱۵	۸-۲ متغیرهای ابزاری (IV) در رگرسیون ساده
۳۱۹	۸-۳ واریانس تخمین‌زننده IV
۳۲۱	۸-۴ ضریب تعیین (R^2)
۳۲۲	۸-۵ متغیرهای ابزاری در رگرسیون چند متغیره
۳۲۴	۸-۶ تخمین‌زننده IV در حالت عمومی
۳۲۷	۸-۷ تخمین‌زننده حداقل مربعات دومرحله‌ای (2SLS)
۳۲۸	۸-۸ آماره F در روش متغیرهای ابزاری
۳۲۹	۸-۹ آزمون سارگان برای بررسی اعتبار متغیرهای ابزاری
۳۳۰	۸-۱۰ آزمون هاسمن

۳۳۳	مسائل
۳۳۴	ضمیمه فصل هشتم: آزمون‌های خاص در Stata
۳۳۷	فصل نهم: مدل‌های غیرخطی
۳۳۷	۹-۱ مقدمه
۳۳۷	۹-۲ رگرسیون خطی
۳۳۸	۹-۳ رگرسیون‌های غیرخطی قابل تبدیل به خطی
۳۳۸	۹-۴ رگرسیون غیرخطی
۳۴۰	۹-۵ فروض مدل رگرسیون غیرخطی
۳۴۱	۹-۶ تخمین زنده حد اقل مربعات غیرخطی
۳۴۱	۹-۶-۱ الگوریتم گاوس-نیوتن
۳۵۱	۹-۶-۲ الگوریتم نیوتن-رافسون
۳۵۱	۹-۶-۳ مقایسه الگوریتم‌های گاوس-نیوتن و نیوتن-رافسون
۳۵۵	۹-۷ روش حداکثر درستمایی
۳۶۳	۹-۸ آزمون محدودیت‌ها در مدل‌های غیرخطی
۳۶۸	مسائل
۳۶۹	ضمیمه فصل نهم: رگرسیون غیرخطی در Stata
۳۷۱	فصل ۱۰: مدل‌های با وقفه توزیعی
۳۷۱	۱۰-۱ مقدمه
۳۷۱	۱۰-۲ اثرات تأخیری
۳۷۲	۱۰-۳ تخمین مدل‌های با وقفه توزیعی
۳۷۶	۱۰-۴ الگوی وقفه خطی
۳۷۸	۱۰-۵ الگوی وقفه ۷ معکوس
۳۸۰	۱۰-۶ الگوی وقفه چندجمله‌ای: روش آلمون
۳۸۸	۱۰-۷ مدل‌های با وقفه نامحدود: تبدیل کوپک
۳۹۲	۱۰-۸ الگوی وقفه پاسکال
۳۹۴	۱۰-۹ مبانی نظری مدل‌های با وقفه توزیعی
۳۹۷	۱۰-۱۰ مدل‌های خودرگرسیون با وقفه توزیعی (ARDL)
۴۰۴	مسائل
۴۰۶	ضمیمه فصل دهم: برآورد مدل‌های با وقفه توزیعی در Stata

۴۰۷	فصل یازدهم: سری‌های زمانی یک متغیره
۴۰۷	۱۱-۱ مقدمه
۴۰۸	۱۱-۲ برخی مفاهیم سری‌های زمانی
۴۰۸	۱۱-۲-۱ فرایند اکیداً مانا
۴۰۸	۱۱-۲-۲ فرایند مانای ضعیف
۴۰۹	۱۱-۲-۳ فرایند تصادفی محض
۴۱۰	۱۱-۲-۴ آزمون معنادار بودن ضرایب خودهمبستگی
۴۱۴	۱۱-۳ فرایند میانگین متحرک
۴۲۱	۱۱-۴ فرایند خودرگرسیون
۴۳۴	۱۱-۵ قضیه تجزیه ولد
۴۳۵	۱۱-۶ ضرایب خودهمبستگی جزئی
۴۳۶	۱۱-۷ معکوس‌پذیری $MA(q)$
۴۳۹	۱۱-۸ فرایند $ARMA$
۴۴۰	۱۱-۹ مدل سازی $ARMA$: روش باکس-جنکینز
۴۴۴	۱۱-۱۰ استفاده از معیارهای اطلاعات برای انتخاب مدل $ARMA$
۴۴۵	۱۱-۱۱ مدل‌های $ARIMA$
۴۴۶	۱۱-۱۲ پیش‌بینی با استفاده از مدل‌های سری زمانی
۴۴۶	۱۱-۱۲-۱ معیارهای ارزیابی پیش‌بینی
۴۴۹	۱۱-۱۲-۲ پیش‌بینی با مدل MA
۴۵۰	۱۱-۱۲-۳ پیش‌بینی با مدل AR
۴۵۱	۱۱-۱۲-۴ پیش‌بینی ایستا و پویا
۴۵۵	مسائل
۴۵۷	ضمیمه فصل یازدهم: مدل‌های $ARIMA$ در Stata
۴۶۱	فصل دوازدهم: مانایی، ریشه واحد و هم‌انباشتی
۴۶۱	۱۲-۱ مقدمه
۴۶۱	۱۲-۲ مانایی
۴۶۲	۱۲-۳ مانایی ضعیف
۴۶۳	۱۲-۴ سری‌های زمانی مانا
۴۶۵	۱۲-۵ روند قطعی
۴۶۶	۱۲-۶ روند تصادفی
۴۶۹	۱۲-۷ ترکیب روند قطعی و روند تصادفی
۴۷۱	۱۲-۸ روندزدایی

۴۷۲	۹-۱۲ آزمون ریشه واحد
۴۸۰	۱۰-۱۲ آزمون ریشه واحد و تغییر ساختاری
۴۸۵	۱۱-۱۲ هم‌انباشتگی
۴۸۹	۱۲-۱۲ آزمون هم‌انباشتگی
۴۹۲	۱۳-۱۲ مدل‌های تصحیح خطا (ECM)
۴۹۴	۱۴-۱۲ تخمین مدل تصحیح خطا
۴۹۵	مسائل
۴۹۸	ضمیمه فصل دوازدهم: آزمون‌های مانایی در Stata
۵۰۱	فصل سیزدهم: سری‌های زمانی فصلی
۵۰۱	۱-۱۳ مقدمه
۵۰۲	۲-۱۳ الگوی فصلی قطعی
۵۰۲	۱-۲-۱۳ متغیرهای مجازی فصلی
۵۰۴	۲-۲-۱۳ الگوهای مثلثاتی
۵۰۹	۳-۱۳ مدل‌های ARMA فصلی (SARMA)
۵۱۳	۴-۱۳ مدل ARIMA فصلی (SARIMA)
۵۱۶	۵-۱۳ ضرایب خودهمبستگی سری‌های زمانی فصلی
۵۱۹	۶-۱۳ ریشه واحد فصلی
۵۲۳	۷-۱۳ آزمون ریشه واحد فصلی
۵۳۰	مسائل
۵۳۱	ضمیمه فصل سیزدهم: ریشه واحد فصلی در Stata
۵۳۵	فصل چهاردهم: مدل‌های تغییرپذیری
۵۳۵	۱-۱۴ مقدمه
۵۳۵	۲-۱۴ واریانس ناهمسانی
۵۳۹	۳-۱۴ تغییرپذیری و ناهمسانی
۵۴۰	۴-۱۴ مدل ARCH
۵۴۲	۵-۱۴ آزمون ARCH
۵۴۵	۶-۱۴ محدودیت‌های مدل ARCH
۵۴۵	۷-۱۴ مدل ARCH تعمیم‌یافته (GARCH)
۵۴۶	۸-۱۴ تخمین مدل‌های ARCH و GARCH
۵۵۲	۹-۱۴ مدل GARCH نامتقارن
۵۵۳	۱-۹-۱۴ مدل GJR

۵۵۴	TARCH مدل ۱۴-۹-۲
۵۵۶	EGARCH مدل ۱۴-۹-۳
۵۵۸	۱۴-۹-۴ آزمون عدم تقارن
۵۶۱	۱۴-۹-۵ منحنی تأثیر خبر
۵۶۲	۱۴-۱۰ وارد نمودن GARCH در معادله میانگین شرطی (ARCH-M)
۵۶۴	۱۴-۱۱ GARCH با اجزاء موقتی و دائمی
۵۶۵	۱۴-۱۲ پیش‌بینی با مدل‌های GARCH
۵۶۹	۱۴-۱۳ مدل‌های GARCH چندمتغیره (MGARCH)
۵۷۷	مسائل
۵۸۰	ضمیمه فصل چهاردهم: مدل‌های GARCH در Stata
۵۸۷	فصل پانزدهم: مدل‌های تغییر جهت
۵۸۷	۱۵-۱ مقدمه
۵۸۹	۱۵-۲ تغییرات فصلی
۵۹۱	۱۵-۳ توابع خطی قطعه‌ای
۵۹۳	۱۵-۴ مدل‌های تغییر جهت مارکف
۵۹۴	۱۵-۴-۱ مبانی مدل‌های تغییر جهت مارکف
۶۰۱	۱۵-۴-۲ کاربردی از مدل تغییر جهت مارکف
۶۰۴	۱۵-۵ مدل‌های خودرگرسیون آستانه
۶۰۹	مسائل
۶۱۱	فصل شانزدهم: معادلات به‌ظاهر نامرتبط (SUR)
۶۱۱	۱۶-۱ مقدمه
۶۱۱	۱۶-۲ الگوی ساده معادلات به‌ظاهر نامرتبط
۶۱۲	۱۶-۳ تخمین‌زننده‌های OLS در معادلات به‌ظاهر نامرتبط
۶۱۳	۱۶-۴ تخمین‌زننده‌های GLS در معادلات به‌ظاهر نامرتبط
۶۱۵	۱۶-۵ شرایط یکسان بودن OLS و GLS
۶۱۷	۱۶-۶ تخمین‌زننده حداقل مربعات تعمیم یافته عملی (FGLS)
۶۱۷	۱۶-۷ کارایی GLS در معادلات به‌ظاهر نامرتبط
۶۲۰	۱۶-۸ آزمون قطری بودن Σ
۶۲۱	مسائل
۶۲۳	ضمیمه فصل شانزدهم: معادلات به‌ظاهر نامرتبط (SUR) در Stata

۶۲۵	فصل هفدهم: معادلات همزمان
۶۲۵	۱۷-۱ مقدمه
۶۲۵	۱۷-۲ سیستم معادلات همزمان: تعاریف و مفاهیم
۶۳۲	۱۷-۳ تخمین معادلات فرم ساختاری از روش OLS و تورش معادلات همزمان
۶۳۴	۱۷-۴ تخمین معادلات فرم خلاصه شده با OLS و مشکل برآورد ضرایب ساختاری
۶۳۵	۱۷-۵ شناسایی (تشخیص) معادلات فرم ساختاری
۶۳۵	۱۷-۵-۱ انواع معادلات ساختاری بر اساس قابلیت شناسایی
۶۳۶	۱۷-۵-۲ شرط درجه‌ای
۶۳۸	۱۷-۵-۳ شرط رتبه‌ای
۶۴۰	۱۷-۵-۴ تشخیص معادلات با استفاده از محدودیت روی ماتریس واریانس-کرواریانس
۶۴۲	۱۷-۶ تخمین سیستم معادلات همزمان
۶۴۲	۱۷-۶-۱ روش‌های تک معادله‌ای
۶۴۳	الف) تخمین سیستم معادلات بازگشتی با روش OLS
۶۴۵	ب) تخمین معادلات همزمان با روش حداقل مربعات غیرمستقیم (ILS)
۶۴۶	ج) برآورد معادلات بیش از حد مشخص با روش 2SLS
۶۴۷	د) روش حداکثر درستنمایی با اطلاعات محدود (LIML)
۶۴۸	۱۷-۶-۲ روش‌های سیستمی
۶۴۸	الف) روش حداقل مربعات سه مرحله‌ای (3SLS)
۶۴۹	ب) برآورد سیستم معادلات همزمان با روش حداکثر درستنمایی با اطلاعات
۶۵۴	ضمیمه فصل هفدهم
۶۵۴	۱- سیستم معادلات همزمان
۶۵۶	۲- شناسایی معادلات
۶۵۹	۳ شرایط رتبه‌ای و درجه‌ای برای تشخیص معادلات
۶۶۳	۴- روش‌های تخمین سیستم معادلات همزمان
۶۶۳	۴-۱ روش‌های تک معادله‌ای
۶۶۳	الف) روش OLS
۶۶۴	ب) روش متغیرهای ابزاری (IV)
۶۶۵	ج) روش حداقل مربعات دو مرحله‌ای (2SLS)
۶۶۸	د) روش حداکثر درستنمایی با اطلاعات محدود (LIML)
۶۷۲	۴-۲ روش‌های سیستمی
۶۷۲	الف) روش 3SLS
۶۷۷	ب) روش حداکثر درستنمایی با اطلاعات کامل (FIML)

۶۸۱	مسائل
۶۸۵	ضمیمه فصل هفدهم: برآورد معادلات همزمان در Stata
۶۸۷	فصل هجدهم: مدل‌های خودرگرسیون برداری (VAR)
۶۸۷	۱۸-۱ مقدمه
۶۸۷	۱۸-۲ فرم ساختاری VAR
۶۸۸	۱۸-۳ فرم استاندارد (فرم حل شده) VAR
۶۹۱	۱۸-۴ VAR مقید و نامقید
۶۹۱	۱۸-۵ انتخاب طول وقفه در مدل‌های VAR
۶۹۲	۱۸-۶ شناسایی معادلات VAR
۶۹۶	۱۸-۷ تخمین حداکثر درستی
۶۹۸	۱۸-۸ آزمون روابط علی
۷۰۰	۱۸-۹ توابع واکنش
۷۰۴	۱۸-۱۰ تجزیه واریانس
۷۰۷	۱۸-۱۱ مانایی در مدل‌های VAR
۷۱۶	مسائل
۷۱۷	ضمیمه فصل هجدهم: مدل‌های VAR در Stata
۷۲۵	فصل نوزدهم: مدل‌های تصحیح خطای برداری (VECM)
۷۲۵	۱۹-۱ مقدمه
۷۲۵	۱۹-۲ نامانایی و هم‌انباشتگی در مدل‌های VAR
۷۲۸	۱۹-۱) VAR هم‌انباشته
۷۳۰	۱۹-۳ هم‌انباشتگی و مدل تصحیح خطای برداری (VECM)
۷۳۱	۱۹-۴ روش جوهانسن
۷۳۱	۱۹-۴-۱ تخمین ضرایب با روش حداکثر درستی
۷۴۵	۱۹-۴-۲ تعیین تعداد بردارهای هم‌انباشتگی
۷۴۶	آزمون اثر جوهانسون
۷۴۷	آزمون بزرگترین مقدار ویژه (λ_{\max})
۷۴۷	۱۹-۴-۳ نرمال‌سازی بردارهای هم‌انباشتگی
۷۴۸	۱۹-۴-۴ شناسایی روابط هم‌انباشتگی و آزمون محدودیت‌های خطی
۷۵۰	۱۹-۴-۵ عرض از مبدأ و روند در مدل VAR و VECM
۷۶۰	مسائل
۷۶۱	ضمیمه فصل نوزدهم: مدل‌های VECM در Stata

۷۶۵	فصل بیستم: داده‌های ترکیبی
۷۶۵	۲۰-۱ مقدمه
۷۶۵	۲۰-۲ داده‌های ترکیبی
۷۷۱	۲۰-۳ مدل‌های رگرسیونی داده‌های ترکیبی
۷۷۳	۲۰-۴ علائم و عملگرها
۷۷۸	۲۰-۵ مدل تجمیعی
۷۸۱	۲۰-۶ مدل اثرات ثابت
۷۸۶	۲۰-۷ آزمون معنادار بودن اثرات ثابت
۷۸۶	۲۰-۸ تخمین زنده‌های درون‌گروهی و بین‌گروهی
۷۹۱	۲۰-۹ مدل اثرات تصادفی
۷۹۴	تخمین زنده GLS
۸۰۰	۲۰-۱۰ آزمون اثرات تصادفی
۸۰۲	۲۰-۱۱ آزمون هاسمن برای مدل اثرات تصادفی
۸۰۵	۱۳-۱۲ مدل اثرات دو طرفه
۸۲۱	۲۰-۱۲ آزمون ریشه واحد در داده‌های ترکیبی
۸۲۲	۲۰-۱۲-۱ آزمون ریشه واحد مشترک
۸۲۴	۲۰-۱۲-۱ آزمون‌های ریشه واحد مقطعی
۸۲۷	مسائل
۸۲۹	ضمیمه فصل بیستم: برآورد مدل داده‌های ترکیبی در Stata
۸۳۵	فصل بیست و یکم: متغیرهای وابسته محدود (مدل‌های لاجیت و پروبیت)
۸۳۵	۲۱-۱ مقدمه
۸۳۶	۲۱-۲ مدل‌های دو انتخابی
۸۳۷	۲۱-۳ مدل احتمال خطی (LPM)
۸۴۳	۲۱-۴ نظریه مطلوبیت تصادفی
۸۴۶	۲۱-۵ مدل پروبیت
۸۵۳	۱۹-۶ مدل لاجیت
۸۵۷	۲۱-۷ معیارهای خوبی برازش
۸۶۰	۲۱-۸ شاخص انحراف
۸۶۶	۲۱-۸ آزمون محدودیت‌ها در مدل‌های پروبیت و لاجیت
۸۶۷	مسائل
۸۶۸	ضمیمه فصل بیست و یکم: مدل‌های پروبیت و لاجیت در Stata

۸۷۱	فصل بیست و دوم: متغیرهای وابسته محدود (مدل‌های منقطع؛ سانسور شده و شمارشی)
۸۷۱	۲۲-۱ مقدمه
۸۷۱	۲۲-۲ توزیع‌های منقطع
۸۷۵	۲۲-۳ امید ریاضی و واریانس منقطع
۸۷۵	۲۲-۴ رگرسیون منقطع
۸۸۲	۲۲-۵ داده‌های سانسور شده
۸۸۲	۲۲-۶ توزیع نرمال سانسور شده
۸۸۴	۲۲-۷ رگرسیون سانسور شده: مدل توییت
۸۸۵	۲۲-۷-۱ مدل توییت
۸۸۵	۲۲-۷-۲ تفسیر نتایج مدل توییت
۸۹۱	۲۲-۸ مدل‌های شمارشی: توزیع پوآسن
۸۹۱	۲۲-۸-۱ توزیع پوآسن
۸۹۳	۲۲-۸-۳ معیارهای خوبی برازش
۸۹۴	۲۲-۸-۴ آزمون فرضیه
۸۹۴	۲۲-۸-۵ تفسیر نتایج مدل پوآسن
۸۹۵	۲۲-۸-۶ محدودیت مدل پوآسن
۸۹۸	مسائل
۸۹۹	ضمیمه فصل بیست و دوم: کاربردهای Stata
۹۰۳	فصل بیست و سوم: مقدمه‌ای بر اقتصادسنجی بیزین
۹۰۳	۲۳-۱ مقدمه
۹۰۴	۲۳-۲ توزیع پیشین و پسین
۹۱۰	۲۳-۳ تخمین زننده بیزین
۹۱۱	۲۳-۴ تابع زیان
۹۱۳	۲۳-۵ تخمین به‌عنوان مسئله تصمیم‌گیری
۹۱۵	۲۳-۶ تخمین بیزین و کلاسیک
۹۱۹	۲۳-۷ آزمون فرضیه در روش بیزین
۹۲۲	۲۳-۸ تخمین ضرایب رگرسیون با روش بیزین
۹۲۳	۲۳-۸-۱ تابع درستنمایی
۹۲۷	۲۳-۸-۲ توزیع پسین ضرایب رگرسیون و تخمین بیزین
۹۲۸	۲۳-۸-۳ توزیع‌های پیشین با اطلاعات غیر مفید
۹۳۲	۲۳-۸-۴ توزیع‌های پیشین با اطلاعات مفید

۹۴۲	۵-۸-۲۳ تخمین نقطه‌ای و تابع زیان
۹۴۳	۶-۸-۲۳ آزمون فرضیه
۹۴۵	مسائل
۹۴۹	ضمائم
۹۵۱	ضمیمه الف: معادلات تفاضلی
۹۶۳	ضمیمه ب: مقادیر ویژه
۹۶۹	ضمیمه ج: بردارها و ماتریس‌ها
۹۸۵	ضمیمه د: جداول آماری
۹۹۵	منابع
۹۹۹	واژه‌نامه انگلیسی-فارسی
۱۰۰۷	واژه‌نامه فارسی-انگلیسی
۱۰۱۵	نمایه موضوعی

فهرست کاربردهای Eviews

صفحه	عنوان
۳۲	آشنایی مقدماتی با نرم افزار Eviews
۳۲	ایجاد فایل کاری در Eviews
۳۵	ورود داده ها در Eviews
۳۶	وقته ها و تفاضل ها در Eviews
۳۷	تغییر نام متغیرها در Eviews
۳۷	متغیر زمان در Eviews
۳۷	اصلاح داده های وارد شده در Eviews
۳۷	مشاهده داده های وارد شده در Eviews
۳۸	تمودارها در Eviews
۳۹	تغییر دوره زمانی در Eviews
۸۰	برآورد رگرسیون ساده در Eviews
۸۵	پیش بینی در Eviews
۸۸	برآورد روابط معکوس در Eviews
۸۹	برآورد معادله لگاریتمی در Eviews

۹۰	برآورد تابع نمایی در Eviews
۹۲	برآورد رگرسیون انحراف از میانگین در Eviews
۹۳	برآورد رگرسیون متغیرهای استاندارد شده در Eviews
۹۵	برآورد معادله روند در Eviews
۹۶	برآورد معادله رشد در Eview
۹۶	برآورد معادلات غیرخطی در Eviews
۹۹	محاسبه کوواریانس در Eviews
۱۰۲	محاسبه ضریب همبستگی در Eviews
۱۳۵	برآورد رگرسیون چندمتغیره در Eviews
۱۴۶	آزمون محدودیت‌ها (آزمون والد) در Eviews
۱۶۷	برآورد واریانس وایت در Eviews
۱۷۳	آزمون‌های واریانس ناهمسانی در Eviews
۱۷۷	آزمون وایت در Eviews
۱۸۳	روش GLS در Eviews
۱۹۴	آزمون دوربین - واتسون در Eviews
۱۹۵	آزمون بروش - گادفری در Eviews
۲۰۰	خودهمبستگی و مدل‌های پویا در Eviews
۲۰۲	رفع خودهمبستگی در استفاده از AR و MA در Eviews
۲۰۶	آزمون نرمال بودن در استفاده از Eviews
۲۳۱	متغیرهای مجازی در Eviews
۲۴۷	آزمون معنی دار بودن رگرسیون با استفاده از نسبت درست‌نمایی در Eviews
۲۷۲	محاسبه ضرایب همبستگی ساده در Eviews
۲۷۸	آزمون RESET رمزی در Eviews
۲۸۴	آزمون متغیرهای حذف شده در استفاده از Eviews
۲۸۶	آزمون متغیرهای نامربوط در استفاده از Eviews
۲۸۹	آزمون نقطه شکست چاو در Eviews
۲۹۲	آزمون پیش‌بینی چاو در Eviews

۲۹۳	برآوردهای بازگشتی در Eviews
۲۹۷	آزمون پیش‌بینی یک‌قدمی در Eviews
۲۹۹	آزمون مجموع تجمعی خطاها (CUSUM) در Eviews
۳۰۰	آزمون مجموع مجذور تجمعی خطاهای بازگشتی (CUSUMQ) در Eviews
۳۰۲	آزمون ثبات ضرایب با استفاده از متغیرهای مجازی در Eviews
۳۰۶	آزمون علیت گرانجر در Eviews
۳۳۱	متغیرهای ابزاری در Eviews
۳۶۱	برآورد مدل‌های غیرخطی در Eviews
۳۶۴	آزمون محدودیت‌ها در Eviews
۳۷۶	تخمین مدل با وقفه توزیعی در Eviews
۳۷۸	برآورد مدل وقفه خطی در Eviews
۳۸۰	برآورد مدل V معکوس در Eviews
۳۸۳	روش آلمون در Eviews
۳۹۲	تبدیل کوپک در Eviews
۳۹۴	الگوی وقفه پاسکال در Eviews
۴۰۴	برآورد مدل ECM در Eviews
۴۱۰	ایجاد فرایند تصادفی محض در Eviews
۴۱۲	برآورد ضرایب خودهمبستگی در Eviews
۴۲۰	ایجاد فرایند MA در Eviews
۴۳۰	ایجاد فرایند AR در Eviews
۴۴۱	برآورد مدل‌های ARMA در Eviews
۴۴۳	بازبینی مدل با استفاده از Eviews
۴۴۵	معیارهای اطلاعات در Eviews
۴۵۳	پیش‌بینی سری‌های زمانی در Eviews
۴۷۴	آزمون ریشه واحد در Eviews
۴۷۹	آزمون فیلپس-پرون در Eviews
۴۸۳	آزمون ریشه واحد در حالت شکست ساختاری در Eviews

۴۹۰	آزمون هم‌انباشتگی در Eviews
۵۲۸	آزمون ریشه واحد فصلی در Eviews
۵۴۳	آزمون ARCH در Eviews
۵۴۹	تخمین مدل GARCH در Eviews
۵۵۳	برآورد مدل GJR در Eviews
۵۵۵	برآورد مدل TARCH در Eviews
۵۵۷	برآورد مدل EGARCH در Eviews
۵۶۳	برآورد GARCH-M در Eviews
۵۶۴	برآورد GARCH با اجزاء موقتی و دائمی در Eviews
۵۶۷	پیش‌بینی واریانس شرطی در Eviews
۵۷۳	تخمین GARCH چند متغیره در Eviews
۵۹۲	آزمون تغییر جهت در Eviews
۶۲۰	برآورد مدل SUR در Eviews
۶۴۹	تخمین معادلات همزمان در Eviews
۷۱۲	برآورد مدل VAR در Eviews
۷۵۳	برآورد مدل VECM در Eviews
۸۰۸	تخمین مدل داده‌های ترکیبی در Eviews
۸۲۴	آزمون ریشه واحد داده‌های ترکیبی در Eviews
۸۴۲	برآورد مدل LPM در Eviews
۸۶۴	تخمین مدل پرویت و لاجیت در Eviews
۸۷۸	برآورد رگرسیون منقطع در Eviews
۸۹۰	برآورد رگرسیون سانسور شده (مدل توییت) در Eviews
۸۹۶	برآورد مدل پواسن در Eviews

فهرست کاربردهای Stata

صفحه	عنوان
۴۲	آشنایی مقدماتی با نرم افزار Stata
۴۲	ایجاد فایل کاری و ورود داده ها در Stata
۴۳	مشاهده و اصلاح داده های وارد شده در Stata
۴۳	توصیف کلی متغیرها در Stata
۴۵	معرفی منوی Statistics در Stata
۴۶	ایجاد متغیر جدید در Stata
۴۷	متغیر زمان در Stata
۴۷	نمودارها در Stata
۴۹	سایر فرمان ها در Stata
۴۹	افزودن دامنه در Stata
۴۹	سایر علائم در Stata
۵۰	لحاظ نکردن برخی از مشاهدات در Stata
۵۰	حذف یک متغیر در Stata
۵۰	نشان گذاری متغیرها در Stata

۱۱۰	برآورد رگرسیون ساده در Stata
۱۱۲	محاسبه مقادیر تخمینی و باقیمانده‌ها در Stata
۱۱۲	پیش‌بینی در Stata
۱۱۴	محاسبه ماتریس واریانس-کوواریانس ضرایب در Stata
۱۱۵	برآورد معادلات غیرخطی در Stata
۱۱۶	محاسبه ضرایب همبستگی در Stata
۱۵۵	برآورد معادلات رگرسیون چند متغیره در Stata
۱۵۶	آزمون محدودیت‌ها (آزمون والد) در Stata
۱۵۷	تخمین رگرسیون مقید در Stata
۲۱۲	آزمون‌های واریانس ناهمسانی در Stata
۲۱۴	برآورد واریانس مستحکم وایت در Stata
۲۱۴	روش GLS در Stata
۲۱۵	آزمون خودهمبستگی در Stata
۲۱۵	آزمون دورین-واتسون در Stata
۲۱۵	آزمون نرمال بودن در Stata
۲۳۴	متغیرهای مجازی در Stata
۳۱۰	آزمون حذف متغیرهای مهم در Stata
۳۱۱	آزمون متغیرهای زائد در Stata
۳۱۱	آزمون چاو در Stata
۳۱۲	آزمون علیت گرانجر در Stata
۳۳۴	متغیرهای ابزاری در Stata
۳۳۵	آزمون هاسمن در Stata
۳۶۹	برآورد معادلات غیرخطی در Stata
۴۰۶	تخمین مدل‌های با وقفه توزیعی در Stata
۴۵۶	محاسبه ضرایب خودهمبستگی در Stata
۴۵۸	برآورد مدل‌های ARIMA در Stata
۴۶۰	پیش‌بینی مدل‌های ARIMA در Stata

۴۶۸	آزمون ریشه واحد در Stata
۵۰۰	آزمون هم‌انباشتگی در Stata
۵۳۱	آزمون ریشه واحد فصلی در Stata
۵۸۰	آزمون ARCH در Stata
۵۸۱	تخمین مدل‌های GARCH در Stata
۵۸۲	برآورد مدل GARCH(p,q) در Stata
۵۸۴	برآورد مدل TARCH در Stata
۵۸۵	برآورد مدل EGARCH در Stata
۵۸۵	برآورد GARCH-M در Stata
۶۲۳	برآورد مدل SUR در Stata
۶۸۵	تخمین معادلات همزمان در Stata
۷۱۷	برآورد مدل VAR در Stata
۷۶۱	برآورد مدل VECM در Stata
۸۲۹	تخمین مدل داده‌های ترکیبی در Stata
۸۳۴	آزمون ریشه واحد داده‌های ترکیبی در Stata
۸۶۸	تخمین مدل پرویت و لاجیت در Stata
۸۹۹	برآورد رگرسیون منقطع در Stata
۹۰۰	برآورد رگرسیون سانسور شده (مدل توییت) در Stata
۹۰۱	برآورد مدل پواسن در Stata

مقدمه

کتاب حاضر در راستای تدوین مجموعه‌ای نسبتاً جامع از مباحث اقتصاد سنجی برای دانشجویان کارشناسی و کارشناسی ارشد رشته‌های اقتصاد و مالی می‌باشد. نسخه‌های قبلی این کتاب صرفاً شامل بخشی از مباحث اقتصاد سنجی بود که به صورت مقدماتی و آزمایشی به چاپ رسید. اکنون مجموعه کامل‌تری از این مباحث تهیه شده است که می‌تواند نیازهای مخاطبان بیشتری را تأمین نماید. مباحث کتاب به دو بخش مقدماتی و پیشرفته تقسیم شده است که به ترتیب شامل جلد ۱ و ۲ می‌باشد. در تدوین این مجموعه سعی شده که اولاً مبانی نظری به طور کامل ارائه گردد، ثانیاً ویژگی کاربردی مباحث حفظ شود و ثالثاً همراه با کاربرد نرم‌افزارها باشد که در این خصوص از دو نرم افزار رایج، Eviews و Stata استفاده شده است.

مباحث اقتصاد سنجی دامنه وسیعی از مطالب را از سطوح مقدماتی تا پیشرفته و از مباحث کاربردی تا نظری شامل می‌شود. با توجه به گستردگی مباحث، تنظیم کتابی که بتواند نیاز مخاطبین آن را تأمین نماید، بسیار دشوار است. با توجه به این نکات، در این کتاب سعی بر آن است که با رعایت حد میانه‌ای از تئوری و کاربرد، نیاز مخاطبین تأمین گردد. در این کتاب، تا حدود زیادی سعی شده تا مباحث اولیه با فشردگی بیشتری بیان شود تا امکان ارائه مباحث جدیدتر فراهم گردد. از طرف دیگر، چون برآورد معادلات و تحلیل مباحث، بدون استفاده از نرم‌افزار امکان‌پذیر نیست، لذا در پایان هر مبحث، کاربرد آن با استفاده از نرم‌افزار Eviews و سپس در پایان هر فصل، کاربردهای نرم‌افزار Stata نیز ارائه شده است. علاوه بر این، داده‌های مورد استفاده

همراه با نرم‌افزار Eviews و Stata نیز در قالب یک CD ارائه شده است تا امکان استفاده همزمان از کتاب و نرم‌افزار فراهم گردد. همچنین در هر جایی که کاربردهای Eviews و Stata آمده است، نام فایل مورد استفاده نیز درج شده تا امکان انجام مستقیم آنها فراهم شود. در تنظیم این کتاب از منابع مختلفی استفاده شده است که البته در مواردی، کتاب اقتصادسنجی مالی بروکس (۲۰۰۱ و ۲۰۰۸) و اقتصادسنجی گرین (۲۰۱۲) بیش از بقیه، مورد استفاده قرار گرفته است.

این کتاب در دو جلد و ۲۳ فصل تنظیم شده است. فصل اول به کلیاتی راجع به توزیع‌های آماری و آشنایی مقدماتی با نرم‌افزار Eviews و Stata اختصاص دارد. در این فصل مفاهیم و توزیع‌های مهم آماری که همواره در اقتصادسنجی مورد استفاده قرار می‌گیرد، ارائه شده است. همچنین بخشی نیز به نکات اولیه و مقدماتی برای آشنایی با نرم‌افزار Eviews و Stata اختصاص یافته است. فصل دوم اختصاص به مباحث پایه‌ای رگرسیون ساده دارد که در همه کتاب‌های اقتصادسنجی به چشم می‌خورد. در اینجا سعی شده تا مباحث رگرسیون را از توزیع‌های دو متغیره شروع کنیم. این شیوه کمک می‌کند تا مفهوم رگرسیون به‌عنوان امید ریاضی شرطی به‌خوبی توصیف شود. در فصل سوم نیز مباحث مذکور برای حالت‌های چند متغیره ارائه شده است. فصل چهارم اختصاص به نقض فروض کلاسیک و آزمون‌های مربوطه دارد.

در فصل پنجم، متغیرهای مجازی و نحوه استفاده از آنها در مباحث مختلف، ارائه شده است. در فصل ششم سایر موضوعاتی که در کارهای تجربی به‌کار می‌روند، ارائه شده است. این موضوعات عمدتاً شامل تصریح مدل و آزمون‌های مربوطه می‌باشد.

فصل هفتم اختصاص به روش حداکثر درستنمایی و موضوعات و آزمون‌های پیرامون آن دارد. به‌ویژه سه آزمون معروف نسبت درستنمایی، والد و ضریب لاگرانژ به تفصیل بحث شده‌اند. فصل هشتم اختصاص به متغیرهای ابزاری دارد که شامل مباحثی در خصوص روش IV و روش 2SLS می‌باشد.

فصل نهم به رگرسیون غیر خطی و روش‌های تخمین و الگوریتم‌های مربوطه دارد که به تفصیل بحث شده‌اند.

در فصل دهم الگوهای پویای تأخیری بحث شده است. در این فصل، روش‌های مختلف تخمین الگوهای پویا که با وقفه‌های توزیعی همراه هستند ارائه شده است. در پایان این فصل الگوهای ARDL نیز مورد بحث قرار گرفته است.

فصل‌های یازدهم و دوازدهم و سیزدهم به سری‌های زمانی یک متغیره اختصاص دارد. در فصل یازدهم مدل‌های ARIMA و در فصل دوازدهم مسائل مربوط به نامانایی، ریشه واحد و هم‌انباشتگی بحث شده است. فصل سیزدهم نیز اختصاص به سری‌های زمانی فصلی دارد که خصوصیات آنها با سری‌های زمانی معمولی متفاوت است.

در فصل چهاردهم مدل‌های تغییرپذیری ارائه شده است. این مدل‌ها شامل انواع مدل‌های ARCH و GARCH می‌باشند. در فصل پانزدهم نیز نوع خاصی از تغییرات سری‌های زمانی بررسی شده است که موسوم به مدل‌های تغییر جهت هستند.

فصل‌های شانزده تا نوزده اختصاص به سیستم معادلات دارد. در فصل شانزدهم معادلات به‌ظاهر نامرتبط و در فصل هفدهم سیستم معادلات همزمان و انواع روش‌های تخمین آنها ارائه شده است. در فصل هجدهم و نوزدهم نیز سری‌های زمانی چند متغیر تحت عنوان مدل‌های خود رگرسیون برداری (VAR) مدل‌های تصحیح خطای برداری (VECM) ارائه شده‌اند.

داده‌های ترکیبی یا مدل‌های پانل در فصل بیستم ارائه شده است. در این فصل مدل‌های تجمیعی، اثرات ثابت و اثرات تصادفی و آزمون‌ها و روش‌های مربوطه به تفصیل بحث شده است. فصل‌های بیست و یکم و بیست و دوم در مورد متغیرهای محدود بحث می‌کند. در این دو فصل مباحثی در خصوص متغیرهای وابسته محدود از قبیل مدل‌های لاجیت و پروبیت، مدل پواسن، مدل‌های سانسور شده و منقطع بحث شده است.

فصل بیست و سوم مباحث مقدماتی در مورد اقتصادسنجی بیزین ارائه می‌کند. در این فصل ابتدا مباحث اولیه مانند توزیع‌های پسین و پیشین، تخمین‌زننده کلاسیک و بیزین و روش تخمین بیزین در معادلات رگرسیون ارائه شده است.

به‌هرحال گستردگی مباحث اقتصادسنجی، امکان ارائه همه مطالب را میسر نمی‌سازد. بدیهی است که هر چند سعی شده تا مطالب بیشتری ارائه شود ولی هنوز کاستی‌های زیادی وجود دارد. حجم مطالب و تنوع آن به گونه‌ای است که امکان وجود اشتباهات را زیاد می‌کند و بدیهی است که کاستی‌ها و نواقص این کتاب زیاد خواهد بود که بابت آن از اساتید محترم و دانشجویان گرامی عذر تقصیر می‌خواهم. بی‌تردید ارائه نظرات شما می‌تواند در بهبود و ارتقای مطالب کتاب، راهگشا باشد. منتظر دریافت نظرات ارزشمند و اصلاحی شما از طریق ایمیل souri.econometrics@yahoo.com هستم. در پایان لازم می‌دانم از همه همکاران و دانشجویانی که نظرات اصلاحی خود را به اینجانب منعکس نموده‌اند تشکر کنم. همچنین لازم است که از صبر و مساعدت همسرم قدردانی کنم که با تقبل همه مسئولیت‌های زندگی، مرا در نگارش این مجموعه یاری نمودند و همچنین ویرایش و بازخوانی مطالب و صفحه‌آرایی آن را به‌عهده گرفتند، لذا این اثر را به ایشان تقدیم می‌کنم.

علی سوری

بهمن ۱۳۹۲

مروری بر مفاهیم پایه‌ای آمار و نرم‌افزارهای Eviews و Stata

۱-۱ مقدمه

در این فصل ابتدا مروری به برخی از مفاهیم پایه‌ای و توابع آماری که استفاده گسترده‌ای در اقتصادسنجی دارند، خواهیم داشت. سپس به معرفی اجمالی نرم‌افزارهای Eviews و Stata و اصول مقدماتی آنها می‌پردازیم. سایر کاربردهای این نرم‌افزار، در فصول بعدی و همراه با مباحث مربوطه، ارائه خواهند شد.

۱-۲ نمونه تصادفی

نمونه تصادفی قسمتی از «جامعه آماری» است که به‌طور تصادفی انتخاب می‌شود. در اینجا لازم است دو مفهوم را از هم متمایز کنیم که یکی «نمونه مشاهده شده» و دیگری «نمونه تصادفی» است. «نمونه مشاهده شده» فقط شامل اعداد و ارقامی است که بعد از نمونه‌گیری به‌دست می‌آیند. اما «نمونه تصادفی» به مرحله قبل از نمونه‌گیری مربوط می‌شود و نمی‌دانیم که چه مقادیری را مشاهده خواهیم کرد.

مثال ۱-۱: فرض کنید که جامعه آماری شامل ۴ دانشجو است که نمرات آنها در درس آمار شامل ۱۰، ۱۲ و ۱۵ می‌باشد. لذا $N=3$ بوده و می‌خواهیم نمونه‌ای به حجم $n=2$ با

روش جایگزینی انتخاب کنیم. بدیهی است که یکبار نمونه‌گیری را انجام خواهیم داد و بعد از انجام نمونه‌گیری فقط دو عدد (نمره) به‌دست خواهد آمد. اما قبل از انجام نمونه‌گیری نمی‌دانیم که کدام دو عدد (نمره) را به‌دست خواهیم آورد. لذا نمونه تصادفی شامل متغیرهای تصادفی (X_1, X_2) و نمونه مشاهده شده شامل اعداد یا مقادیر (x_1, x_2) خواهد بود. توجه شود که X_1 بیانگر انتخاب اول و X_2 بیانگر انتخاب دوم می‌باشد. تمامی نتایج ممکن برای (X_1, X_2) به‌صورت زیر می‌باشد:

$$\begin{array}{ccc} (1,1) & (1,2) & (1,5) \\ (2,1) & (2,2) & (2,5) \\ (5,1) & (5,2) & (5,5) \end{array}$$

بنابراین $9 (=3^2)$ نتیجه ممکن خواهیم داشت. بدیهی است که فقط یک‌بار نمونه‌گیری انجام می‌شود و لذا «نمونه مشاهده شده» فقط شامل یکی از نمونه‌های فوق خواهد بود.

بنابراین، نمونه تصادفی را به‌صورت زیر تعریف می‌کنیم:

«نمونه تصادفی مجموعه‌ای از n متغیر تصادفی (X_1, X_2, \dots, X_n) است که مستقل از هم بوده و توزیع آنها با توزیع X در جامعه آماری یکسان است.»

۳-۱ توزیع مشترک متغیرهای نمونه یا توزیع مشترک نمونه تصادفی

یکی از نکات مهم در رابطه با نمونه تصادفی این است که هر متغیر نمونه (یعنی X_i) دقیقاً همان ویژگی‌های متغیر تصادفی X در جامعه اصلی را دارد. به‌عنوان مثال فرض کنید جامعه آماری شامل ۱۰ نفر ($N=10$) باشد که متغیر تصادفی X بیانگر بی‌سوادی اعضای این جامعه است:

$$X = 1 \quad \text{بی‌سوادی}$$

$$X = 0 \quad \text{باسوادی}$$

بنابراین اگر نسبت بی‌سوادی برابر با p باشد، در این صورت اگر یک نفر را از این جامعه انتخاب کنیم، احتمال اینکه بی‌سوادی باشد (یا احتمال اینکه $x=1$ باشد) برابر با p است و در غیر این صورت برابر با q یا $1-p$ است.

x	۰	۱
$P(x)$	q	p

و یا می‌توان آن را به صورت تابع احتمال دو نقطه‌ای نشان داد:

$$P(x) = p^x q^{1-x} \quad ; \quad x = 0, 1$$

حال اگر از این جامعه، نمونه‌ای به حجم $n=2$ انتخاب کنیم، در این صورت نمونه تصادفی شامل (X_1, X_2) است. حال سؤال این است که توزیع X_1 چگونه می‌باشد؟
اولاً مقادیر X_1 در نمونه، دقیقاً همان مقادیری است که X در جامعه اصلی اختیار می‌کند. زیرا مقدار مشاهده اول یعنی X_1 یا ۰ است و یا ۱. اما احتمال اینکه $X_1 = 0$ باشد برابر است با احتمال اینکه $X = 0$ باشد که هر دو بستگی به این دارند که چه نسبتی از جامعه بی‌سواد نمی‌باشد (یعنی q). بنابراین، توزیع X_1 دقیقاً همان توزیع X است. به عبارت دقیق‌تر متغیر تصادفی X_1 با متغیر تصادفی X هیچ گونه تفاوتی ندارد.

$$P(x_1) = p^{x_1} q^{1-x_1} \quad ; \quad x_1 = 0, 1 \quad \text{یا} \quad \frac{x_1}{P(x_1)} \bigg| \frac{0}{q} \quad \frac{1}{p}$$

همین استدلال را برای X_2 نیز می‌توان به کار برد.

بنابراین اگر در حالت کل، نمونه تصادفی به حجم n باشد، در این صورت هر یک از متغیرهای تصادفی X_1, X_2, \dots, X_n دقیقاً همان توزیع X در جامعه اصلی را خواهند داشت. در مثال فوق، هر یک از X_i ها توزیع دو نقطه‌ای خواهند داشت:

$$P(x_i) = p^{x_i} q^{1-x_i} \quad x_i = 0, 1 \quad \text{و} \quad i = 1, 2, \dots, n$$

مثال ۲-۱: فرض کنید که در جامعه آماری متغیر تصادفی X بیانگر قد دانشجویان یک

دانشگاه است که دارای توزیع نرمال با میانگین ۱۶۹ و واریانس ۶۴ می‌باشد:

$$X \sim (\mu = 169, \sigma^2 = 64)$$

اگر از این جامعه نمونه‌ای تصادفی به حجم n انتخاب کنیم هر یک از متغیرهای

تصادفی X_1, X_2, \dots, X_n دارای توزیع نرمال خواهند بود:

$$E(X_i) = E(X) = \mu \quad , \quad \text{var}(X_i) = \text{var}(X) = \sigma^2$$

$$X_i \sim (\mu = 169, \sigma^2 = 64)$$

در حالت کلی، برداری از متغیرهای تصادفی یعنی X_1, X_2, \dots, X_n را داریم که مقادیر آنها با x_1, x_2, \dots, x_n و x_n نشان داده می‌شود. حال توزیع مشترک یا احتمال مشترک این نمونه تصادفی برابر است با:

$$P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) \quad (1-1)$$

که بیانگر این است که چقدر احتمال دارد در نمونه‌گیری تصادفی، مقادیر x_1, x_2, \dots, x_n و x_n مشاهده گردد. اما از آنجا که این متغیرها، مستقل از هم می‌باشند لذا احتمال مذکور برابر است با:

$$\begin{aligned} P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) &= P(X_1 = x_1)P(X_2 = x_2) \cdots P(X_n = x_n) \\ &= \prod_{i=1}^n P(X_i = x_i) = \prod_{i=1}^n P(x_i) \end{aligned} \quad (1-2)$$

در حالت پیوسته به جای تابع احتمال، از تابع چگالی استفاده می‌شود که در آن صورت تابع چگالی مشترک به دست می‌آید.

مثال ۱-۳: در مثال ۱-۱ اگر حجم نمونه n باشد، در این صورت توزیع مشترک متغیرهای نمونه عبارت است از:

$$P(X_1 = x_1, \dots, X_n = x_n) = P(x_1) \cdots P(x_n) = p^{\sum_{i=1}^n x_i} q^{n - \sum_{i=1}^n x_i}$$

مثال ۱-۴: در مثال ۱-۲ توزیع مشترک متغیرهای نمونه عبارت است از:

$$\begin{aligned} P(X_1 = x_1, \dots, X_n = x_n) &= f_{X_1}(x_1) \cdots f_{X_n}(x_n) \\ &= f_X(x_1) \cdots f_X(x_n) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} e^{-\frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}} \end{aligned}$$

۱-۴ تابعی از متغیرهای نمونه (آماره)

از آنجا که X_1, X_2, \dots, X_n و X_n متغیرهای تصادفی هستند، لذا هر تابعی از این متغیرها نیز یک متغیر تصادفی است. همان‌طور که خواهیم دید، این توابع نقش مهمی در مباحثی چون تخمین و آزمون فرضیه دارند. شکل کلی چنین توابعی عبارت است از:

$$f(X_1, X_2, \dots, X_n)$$

توجه شود که این تابع، فقط تابعی از متغیرهای نمونه است شامل هیچیک از پارامترهای توزیع X نیست. برخی از انواع مهم این توابع عبارتند از:

$$Y = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i$$

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{\sum_{i=1}^n X_i}{n}$$

$$\tilde{S}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$$

دو تابع نمونه‌ای یا آماره \bar{X} و S^2 بیش از بقیه، مورد استفاده می‌باشد که اولی میانگین نمونه و دیگری واریانس نمونه است.

بر اساس هر یک از توابع فوق می‌توان توابع دیگری را نیز تعریف کرد که در ادامه به آنها خواهیم پرداخت. از آنجا که هر یک از این توابع، متغیرهای تصادفی هستند لذا برای آنها می‌توان تابع احتمال یا چگالی را نیز به دست آورد.

۱-۵ تخمین

موضوع تخمین راجع به برآورد پارامترهای جامعه اصلی است. در اینجا فرض می‌کنیم که توزیع X در جامعه اصلی معلوم است ولی پارامترهای آن نامعلوم هستند. به عنوان مثال فرض کنید که توزیع X در جامعه اصلی، نرمال است اما پارامترهای آن یعنی μ و σ^2 مجهول می‌باشند.

۱-۵-۱ تخمین و تخمین‌زننده

فرض کنید نسبت بی‌سوادی در جامعه‌ای دارای توزیع دوقطه‌ای است که به صورت زیر نشان داده می‌شود:

$$P(x) = p^x q^{1-x} \quad ; \quad x=0,1$$

این توزیع یک پارامتر دارد که p (یعنی نسبت بی‌سواد) است. بنابراین توزیع X معلوم است اما پارامتر این توزیع یعنی p ، نامعلوم می‌باشد. حال با استفاده از اطلاعات نمونه می‌خواهیم p را برآورد نماییم. فرض کنید نمونه‌ای به حجم n انتخاب می‌کنیم. بعد از انجام نمونه‌گیری، مشاهدات ما شامل مقادیر x_1, x_2, \dots, x_n است که بر اساس آن، تخمین p عبارت است از:

$$\frac{x_1 + x_2 + \dots + x_n}{n}$$

هر کدام از x_i ها فقط ۰ یا ۱ هستند. اگر همگی صفر باشند در این صورت تخمین p برابر با ۰ و اگر همگی برابر با ۱ باشند تخمین p برابر با ۱ خواهد بود. حال اگر برخی از x_i ها برابر با ۰ و برخی نیز برابر با ۱ باشند، در این صورت تخمین p بین ۰ و ۱ خواهد بود. در حالت کلی اگر آن تعداد از x_i ها را که برابر با ۱ هستند با m نشان دهیم، در این صورت $m = x_1 + x_2 + \dots + x_n$ بوده و لذا خواهیم داشت:

$$\frac{m}{n} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

بنابراین تخمین p معادل با $\frac{m}{n}$ است. به همین ترتیب اگر بحث خود را معطوف به بعد از نمونه‌گیری کنیم، در این صورت مقدار m معلوم بوده و بر اساس آن، تخمین p به‌دست خواهد آمد. اما قبل از نمونه‌گیری، m یک متغیر تصادفی خواهد بود، زیرا مقدار آن بعد از انجام آزمایش (نمونه‌گیری) معلوم خواهد شد و لذا m یا $\frac{m}{n}$ تابعی از متغیرهای نمونه است:

$$\hat{p} = \frac{m}{n} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

به چنین تابعی «تخمین‌زننده» و یا «برآوردکننده» یا «برآوردگر» و مقدار حاصل از این تابع را که بعد از نمونه‌گیری به‌دست می‌آید «تخمین» یا «برآورد» می‌گوییم. بنابراین تخمین‌زننده هر پارامتری مانند θ را با $\hat{\theta}$ نشان می‌دهیم که تابعی از متغیرهای نمونه است:

$$\hat{\theta} = f(X_1, X_2, \dots, X_n) \quad (1-3)$$

اما بدیهی است که برای پارامتر θ نمی‌توان هر تابع دلخواهی را به‌عنوان تخمین‌زننده تعریف نمود، بلکه هر تخمین‌زننده باید دارای خواصی باشد که در ادامه به آنها می‌پردازیم. برای به‌دست

آوردن تخمین زنده‌هایی که دارای خواص مناسبی باشند، روش‌هایی وجود دارد که ابتدا این روش‌ها را بررسی می‌کنیم.

۱-۵-۲ روش‌های تخمین

برای تخمین پارامترهای مورد نظر، روش‌هایی وجود دارد که هر یک دارای ویژگی‌ها و خواص خود هستند. در اینجا به بررسی این روش‌ها می‌پردازیم.

روش گشتاورها

روش گشتاورها بر مبنای این استدلال ساده قرار دارد که گشتاورهای هر توزیع، تابعی از پارامترهای آن توزیع می‌باشد و لذا می‌توان با حل چنین معادلاتی به تخمین پارامترها بر حسب گشتاورها رسید. به عنوان مثال اگر توزیعی فقط پارامتر θ را داشته باشد، در این صورت اولین گشتاور که همان میانگین می‌باشد، عبارت است از:

$$m_1 = E(X) = g(\theta)$$

حال اگر به جای m_1 مقدار آن را بر حسب اطلاعات نمونه قرار دهیم، خواهیم داشت:

$$\hat{m}_1 = g(\hat{\theta})$$

که \hat{m}_1 گشتاور مرتبه اول نمونه و $\hat{\theta}$ تخمین θ می‌باشد. از حل این معادله خواهیم داشت:

$$\hat{\theta} = h(\hat{m}_1)$$

حال اگر توزیعی دارای دو پارامتر باشد، در این صورت گشتاورهای مرتبه اول و دوم را محاسبه می‌کنیم:

$$m_1 = E(X) = g_1(\theta_1, \theta_2)$$

$$m_2 = E(X^2) = g_2(\theta_1, \theta_2)$$

و با جایگذاری از اطلاعات نمونه به جای گشتاورهای جامعه، خواهیم داشت:

$$\hat{m}_1 = g_1(\hat{\theta}_1, \hat{\theta}_2)$$

$$\hat{m}_2 = g_2(\hat{\theta}_1, \hat{\theta}_2)$$

با حل این دو معادله برای پارامترهای $\hat{\theta}_1$ و $\hat{\theta}_2$ خواهیم داشت:

$$\hat{\theta}_1 = h_1(\hat{m}_1, \hat{m}_2)$$

$$\hat{\theta}_2 = h_2(\hat{m}_1, \hat{m}_2)$$

مثال ۵-۱: فرض کنید X دارای توزیع یکنواخت است:

$$f(x) = \frac{1}{b} \quad 0 < x < b$$

پارامتر b را با استفاده از روش گشتاورها به دست آورید.

$$m_1 = E(X) = \int_0^b x \cdot \frac{1}{b} dx = \frac{x^2}{2b} \Big|_0^b = \frac{b}{2}$$

بنابراین به جای m_1 از \hat{m}_1 و به جای b از \hat{b} استفاده می‌کنیم.

$$\hat{m}_1 = \frac{\hat{b}}{2} \Rightarrow \hat{b} = 2\hat{m}_1$$

که \hat{b} تابعی از \hat{m}_1 می‌باشد.

مثال ۶-۱: فرض کنید که X دارای یکنواخت باشد:

$$f(x) = \frac{1}{b-a}; \quad a < x < b$$

پارامترهای a و b را با استفاده از روش گشتاورها تخمین بزنید.

$$m_1 = \int_a^b x \cdot \frac{1}{b-a} dx = \frac{a+b}{2}$$

$$m_2 = \int_a^b x^2 \cdot \frac{1}{b-a} dx = \frac{b^3 + ab + a^3}{3}$$

که می‌توان آنها را به صورت زیر نوشت:

$$\hat{m}_1 = \frac{\hat{a} + \hat{b}}{2}$$

$$\hat{m}_2 = \frac{\hat{b}^3 + \hat{a}\hat{b} + \hat{a}^3}{3}$$

با حل این معادلات، نتیجه می‌شود:

$$\hat{a} = \hat{m}_1 + \sqrt{3(\hat{m}_2 - \hat{m}_1^2)}$$

$$\hat{b} = \hat{m}_1 - \sqrt{3(\hat{m}_2 - \hat{m}_1^2)}$$

روش حداکثر درستنمایی

روش حداکثر احتمال یا حداکثر درستنمایی یکی از روش‌های مناسب برای برآورد پارامترها

می‌باشد. مبنای این روش بر اساس استدلال زیر است:

فرض کنید X دارای توزیع معینی باشد که فقط یک پارامتر (θ) دارد که آن را به صورت $P(x, \theta)$ نشان می‌دهیم. حال وقتی نمونه‌گیری را انجام دهیم، نتایج حاصل از نمونه‌گیری شامل مقادیر x_1, x_2, \dots, x_n و x_n می‌باشد. احتمال مشاهده شدن این نمونه، عبارت است از:

$$\begin{aligned} P(X_1 = x_1, \dots, X_n = x_n) &= P(X_1 = x_1) \dots P(X_n = x_n) \\ &= P(x_1, \theta) \dots P(x_n, \theta) \end{aligned} \quad (1-4)$$

بدیهی است که مقدار این احتمال بستگی به مقدار θ دارد، زیرا مقادیر متغیرهای تصادفی X_1, X_2, \dots, X_n معلوم شده‌اند و به جای آن، مقادیر x_1, x_2, \dots, x_n را قرار داده‌ایم. مقدار پارامتر θ مجهول است که تعیین‌کننده مقدار این احتمال می‌باشد. لذا مقدار این احتمال در رابطه (1-4) تابعی از θ است که آن را با $L(\theta)$ نشان می‌دهیم. $L(\theta)$ بیانگر «احتمال نمایان شدن نمونه مورد نظر» می‌باشد که به آن «تابع درستنمایی» می‌گوییم.

حال سؤال این است که از بین تمامی نمونه‌هایی که می‌توانستند نمایان شوند، چرا فقط این مقادیر (یعنی x_1, x_2, \dots, x_n) مشاهده شده‌اند. دلیل آن ساده است، زیرا این مشاهدات، بیشترین احتمال یا شانس را برای نمایان شدن داشته‌اند. پس باید $L(\theta)$ بیانگر حداکثر احتمال باشد. لذا مقدار θ که بر حسب مشاهدات نمونه تعیین می‌شود باید به گونه‌ای باشد که احتمال مذکور را حداکثر نماید. برای حداکثر شدن $L(\theta)$ ، شرط زیر را به کار می‌بریم:

$$\frac{\partial L}{\partial \theta} = 0 \Rightarrow \hat{\theta} = g(x_1, x_2, \dots, x_n) \quad (1-5)$$

معمولاً بهتر است که ابتدا از $L(\theta)$ لگاریتم گرفته و سپس نسبت به θ مشتق بگیریم، زیرا آن مقدار از θ که لگاریتم L را حداکثر نماید، L را نیز حداکثر خواهد نمود.^۱

۱- اگر $f(x)$ دارای نقطه حداکثر باشد شرط لازم عبارت است از:

$$f'(x) = 0$$

اما اگر $\ln f(x)$ را حداکثر کنیم، خواهیم داشت:

$$\frac{\partial \ln f(x)}{\partial x} = 0 \Rightarrow \frac{f'(x)}{f(x)} = 0 \Rightarrow f'(x) = 0$$

بنابراین در هر دو حالت، شرط لازم به صورت $f'(x) = 0$ می‌باشد.

مثال ۱-۷: فرض کنید X توزیع دوقطه‌ای دارد:

$$P(x) = p^x (1-p)^{1-x}$$

از این جامعه، نمونه‌ای به حجم n انتخاب می‌شود. تخمین پارامتر p با استفاده از روش حداکثر درستمایی عبارت است از:

$$\begin{aligned} L(p) &= P(x_1, p) \dots P(x_n, p) = p^{x_1} (1-p)^{1-x_1} \dots p^{x_n} (1-p)^{1-x_n} \\ &= p^{\sum x_i} (1-p)^{n-\sum x_i} \\ \ln L(p) &= \sum x_i \ln p + (n - \sum x_i) \ln(1-p) \\ \frac{\partial \ln L}{\partial p} &= \sum x_i \frac{1}{p} + (n - \sum x_i) \frac{-1}{1-p} = 0 \Rightarrow \hat{p} = \frac{\sum x_i}{n} = \bar{x} \end{aligned}$$

بنابراین تابع $L(p)$ به ازای $\hat{p} = \frac{\sum X_i}{n} = \bar{X}$ حداکثر خواهد شد.

بدیهی است که اگر تعداد پارامترها بیشتر باشد مثلاً دو پارامتر θ_1 و θ_2 داشته باشیم، در این صورت تابع درستمایی تابعی از θ_1 و θ_2 است که نسبت به هر دو مشتق گرفته و تخمین‌زننده آنها را به دست می‌آوریم.

روش حداقل مربعات معمولی

این روش یکی از روش‌های مهم در تخمین پارامترها می‌باشد که عمدتاً برای تخمین معادلات رگرسیون به کار می‌رود. جزئیات این روش در فصل‌های بعدی ارائه خواهد شد.

۱-۵-۳ خواص تخمین‌زننده‌ها

از آنجا که برای تخمین یک پارامتر می‌توان تخمین‌زننده‌های متعددی را معرفی نمود، لذا بایستی مناسب‌ترین تخمین‌زننده‌ها را انتخاب نماییم. بنابراین، باید شرایط و خواصی را برای یک تخمین‌زننده خوب تعریف کنیم تا بر اساس چنین معیارهایی بتوان در مورد میزان خوبی یک تخمین‌زننده داوری نمود.

بدون تورش یا نااریب بودن^۱

اگر امید ریاضی یک تخمین‌زننده برابر با پارامتر مورد نظر باشد، آن را تخمین‌زننده بدون تورش (نااریب) گویند:

$$E(\hat{\theta}) = \theta \quad (۱-۶)$$

به عبارت دیگر خاصیت نااریبی به صورت $E(\hat{\theta}) - \theta = 0$ است و اگر تخمین‌زننده دارای اریب باشد، این رابطه به صورت $E(\hat{\theta}) - \theta = B$ می‌باشد که B مقدار تورش (اریب) را نشان می‌دهد.

مثال ۱-۸: فرض کنید X دارای توزیع پواسن با پارامتر λ باشد. برای تخمین λ از


تابع نمونه‌ای یا آماره $\hat{\lambda} = \bar{X} = \frac{\sum x_i}{n}$ استفاده می‌کنیم. می‌توان ثابت نمود که \bar{X} یک تخمین‌زننده نااریب برای λ است:

$$E(\hat{\lambda}) = E(\bar{X}) = E\left(\frac{\sum (X_i)}{n}\right) = \frac{\sum E(X)}{n} = \frac{\sum \lambda}{n} = \frac{n\lambda}{n} = \lambda$$

مفهوم بدون تورش بدین معنا است که تخمین‌زننده «به‌طور متوسط» به پارامتر مورد نظر گرایش دارد. در چنین حالتی، مرکز توزیع $\hat{\theta}$ درست بر روی θ قرار دارد و لذا مقدار حاصل از $\hat{\theta}$ به‌طور متوسط به θ نزدیک خواهد بود. اگر دو تخمین‌زننده $\hat{\theta}_1$ و $\hat{\theta}_2$ برای θ داشته باشیم، نمودار الف تخمین بدون تورش را نشان می‌دهد که مقدار $\hat{\theta}_1$ به‌طور متوسط برابر با θ است، ولی نمودار ب تخمین با تورش را نشان می‌دهد که مقدار $\hat{\theta}_1$ به‌طور متوسط برابر با $\theta + B$ است. لذا $\hat{\theta}_1$ مقدار θ را به‌طور متوسط به اندازه B بیش از حد و یا کمتر از حد، برآورد می‌کند. از طرف دیگر برای تخمین‌زننده‌ای که با افزایش حجم نمونه، مقدار تورش آن کوچک شده و به صفر میل کند، آن را «تخمین‌زننده بدون تورش حدی» می‌گویند.

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta \quad \text{یا} \quad \lim_{n \rightarrow \infty} B = 0 \quad (۱-۷)$$

^۱unbiased



نمودار ۱-۱: تخمین‌زنده‌های بدون تورش و باتورش

مثال ۱-۹: برای تخمین واریانس در جامعه‌ای با توزیع نرمال، نمونه‌ای تصادفی به

حجم n انتخاب می‌شود. تخمین‌زنده واریانس را به صورت $\tilde{S}^2 = \frac{(x_i - \bar{X})^2}{n}$ معرفی

می‌کنیم. آیا \tilde{S}^2 یک تخمین‌زنده نااریب است؟

بدین منظور از رابطه \tilde{S}^2 و توزیع کای‌دو (χ^2) استفاده می‌کنیم^۱:

$$\tilde{S}^2 = \frac{\sum (X_i - \bar{X})^2}{n} = \frac{\sigma^2}{n} \chi_{n-1}^2$$

$$E(\tilde{S}^2) = E\left(\frac{\sigma^2}{n} \chi_{n-1}^2\right) = \frac{\sigma^2}{n} E(\chi_{n-1}^2) = \frac{\sigma^2}{n} (n-1) = \frac{n-1}{n} \sigma^2 = \sigma^2 - \frac{\sigma^2}{n}$$

مقدار

$$E(\tilde{S}^2) - \sigma^2 = -\frac{\sigma^2}{n}$$

تورش \tilde{S}^2 برابر با $-\frac{\sigma^2}{n}$ است. به عبارت دیگر \tilde{S}^2 به طور متوسط مقدار σ^2 را به

اندازه $\frac{\sigma^2}{n}$ کمتر از حد واقعی^۲ برآورد می‌کند. اما چون $\lim_{n \rightarrow \infty} \frac{\sigma^2}{n} = 0$ است، لذا بدون

اریب مجانی می‌باشد.


کارایی (حداقل واریانس)

یکی دیگر از ویژگی‌های تخمین‌زنده‌ها، کوچک بودن واریانس است. برای توضیح این

مطلب، فرض کنید برای تخمین پارامتر θ دو تخمین‌زنده $\hat{\theta}_1$ و $\hat{\theta}_2$ داریم که هر دو بدون تورش،

ولی واریانس $\hat{\theta}_1$ کمتر از $\hat{\theta}_2$ باشد.

^۱توزیع کای‌دو در بخش ۲-۷-۱ ارائه شده است.



نمودار ۱-۲: کارایی تخمین‌زننده‌ها

نمودار فوق نشان می‌دهد که $\hat{\theta}_1$ دارای واریانس کمتری است، لذا تمامی مقادیر ممکن آن در مقایسه با $\hat{\theta}_2$ به θ نزدیکتر هستند. هر تخمین‌زننده‌ای که دارای واریانس کمتری باشد، دارای کارایی بیشتری است. در اینجا کارایی $\hat{\theta}_1$ در مقایسه با $\hat{\theta}_2$ برابر است با:

$$\text{ضریب کارایی } \hat{\theta}_1 \text{ در مقایسه با } \hat{\theta}_2 = \frac{\text{var}(\hat{\theta}_2)}{\text{var}(\hat{\theta}_1)} \quad (1-8)$$

به عنوان مثال، اگر واریانس $\hat{\theta}_2$ برابر با ۵ و واریانس $\hat{\theta}_1$ برابر با ۳ باشد، در این صورت کارایی $\hat{\theta}_1$ در مقایسه با $\hat{\theta}_2$ برابر با $5/3 \approx 1.67$ یا ۶۰ درصد است. این بدان معنا است که کارایی $\hat{\theta}_1$ در نمونه‌ای به حجم ۱۰۰ مشابه کارایی $\hat{\theta}_2$ در نمونه‌ای به حجم ۶۰ می‌باشد.

حال فرض کنید که از بین تمامی تخمین‌زننده‌های θ ، تخمین‌زننده‌ای مانند $\hat{\theta}_*$ وجود داشته باشد که دارای کمترین واریانس باشد. بدیهی است که $\hat{\theta}_*$ کارآترین تخمین‌زننده خواهد بود. حال سایر تخمین‌زننده‌های θ را با $\hat{\theta}_*$ مقایسه می‌کنیم. بنابراین ضریب کارایی هر تخمین‌زننده دلخواه مانند $\hat{\theta}_i$ برابر است با:

$$\text{ضریب کارایی } \hat{\theta}_i = \frac{\text{var}(\hat{\theta}_*)}{\text{var}(\hat{\theta}_i)} \leq 1 \quad (1-9)$$

نامساوی کرامر-رائو، حد پایین واریانس تخمین‌زننده‌های θ است:

$$\text{var}(\hat{\theta}) \geq \frac{1}{E\left[\frac{\partial}{\partial \theta} \ln L(\theta)\right]^2} \quad (1-10)$$

واریانس کارآترین تخمین‌زننده برابر با حد پایین این نامساوی است.

مثال ۱۰-۱: برای تخمین پارامتر μ دو جامعه‌ای با توزیع نرمال، نمونه‌ای به حجم n انتخاب می‌شود. ضریب کارایی \bar{X} به عنوان تخمین زننده μ را حساب کنید.

$$L(\mu, \sigma^2) = \frac{1}{(\sqrt{2\pi}\sigma)^n} e^{-\frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}} \Rightarrow \ln L = -n \ln \sqrt{2\pi}\sigma - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}$$

$$\frac{\partial \ln L}{\partial \mu} = \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2} \Rightarrow E\left[\frac{\partial \ln L}{\partial \mu}\right] = E\left[\frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2}\right]$$

$$= \frac{\sum_{i=1}^n E(x_i - \mu)}{\sigma^2} = \frac{\sum_{i=1}^n 0}{\sigma^2} = \frac{n \cdot 0}{\sigma^2} = 0$$

توجه شود که در محاسبه امید ریاضی $\left(\sum_{i=1}^n (x_i - \mu)\right)$ ، امید ریاضی حاصل ضرب جملات

مقاطع $\left(\sum_{i=1}^n \sum_{j=1}^n (X_i - \mu)(X_j - \mu)\right)$ برابر صفر است، زیرا X_i ها مستقل اند. بدین ترتیب،

کمترین واریانس برای تخمین زننده‌های میانگین در یک جامعه نرمال برابر با $\frac{\sigma^2}{n}$ است.

سازگاری

سازگاری یکی از خواص مجانی تخمین زننده‌ها است و بدین معناست که اگر حجم نمونه افزایش یابد، احتمال اینکه تفاضل $\hat{\theta}$ از θ از هر عدد حقیقی مانند ε کمتر باشد، برابر با ۱ خواهد بود.

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| < \varepsilon) = 1 \quad (1-11)$$

این خاصیت بیانگر این است که وقتی حجم نمونه افزایش یابد، مقدار $\hat{\theta}$ کاملاً به θ نزدیک خواهد شد. شرط فوق را اصطلاحاً «همگرایی در احتمال» می‌گویند و با علامت plim نشان می‌دهند:

$$\text{plim } \hat{\theta} = \theta \quad (1-12)$$

معادل این را می‌توان برحسب واریانس بیان نمود، زیرا واریانس نیز بیانگر انحراف $\hat{\theta}$ از $E(\hat{\theta})$ است. اگر تخمین زننده بدون تورش حدی باشد آنگاه شرایط زیر را تأمین می‌کند:

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta, \quad \lim_{n \rightarrow \infty} \text{var}(\hat{\theta}) = 0. \quad (1-13)$$

اگر با افزایش حجم نمونه، واریانس $\hat{\theta}$ به سمت صفر میل کند، بدین معناست که انحراف $\hat{\theta}$ از θ به صفر خواهد رسید.

مثال ۱-۱۱: برای تخمین میانگین جامعه نرمال، \bar{X} یک تخمین‌زننده سازگار است.

$$\text{var}(\bar{X}) = \text{var}\left(\frac{\sum X_i}{n}\right) = \frac{\sum \text{var}(X_i)}{n^2} = \frac{\sum \sigma^2}{n^2} = \frac{\sigma^2}{n}$$

$$\lim_{n \rightarrow \infty} \text{var}(\bar{X}) = \lim_{n \rightarrow \infty} \frac{\sigma^2}{n} = 0.$$

مثال ۱-۱۲: برای تخمین واریانس جامعه نرمال، \tilde{S}^2 یک تخمین‌زننده باتورش اما سازگار است.

$$\tilde{S}^2 = \frac{\sum (X_i - \bar{X})^2}{n} = \frac{\sigma^2}{n} \chi_{n-1}^2$$

$$\text{var}(\tilde{S}^2) = \text{var}\left(\frac{\sigma^2}{n} \chi_{n-1}^2\right) = \frac{\sigma^4}{n^2} \text{var}(\chi_{n-1}^2) = \frac{\sigma^4}{n^2} 2(n-1) = 2\sigma^4 \left(\frac{1}{n} - \frac{1}{n^2}\right)$$

$$\lim_{n \rightarrow \infty} \text{var}(\tilde{S}^2) = \lim_{n \rightarrow \infty} 2\sigma^4 \left(\frac{1}{n} - \frac{1}{n^2}\right) = 0.$$

کفایت

$\hat{\theta}$ را یک تخمین‌زننده کافی برای θ گویند اگر $\hat{\theta}$ از تمام اطلاعات نمونه که مربوط به برآورد θ است استفاده کند. این تعریف معادل است با اینکه توزیع مشترک X_i ها (اطلاعات نمونه) به شرط $\hat{\theta}$ مستقل از θ باشد. توزیع مشترک X_i ها به شرط $\hat{\theta}$ که با $f(x_1, \dots, x_n | \hat{\theta})$ نشان داده می‌شود بایستی مستقل از θ باشد. اگر این احتمال بستگی به θ داشته باشد، آنگاه مشاهده یک نمونه خاص بستگی به θ دارد. حال اگر این احتمال مستقل از θ باشد، آنگاه نمونه خاصی مانند (x_1, \dots, x_n) که منجر به برآورد θ می‌شوند، برای هر مقدار از θ احتمال یکسانی با سایر نمونه‌ها دارد. احتمال مذکور را می‌توان به صورت زیر نوشت:

$$f(x_1, \dots, x_n | \hat{\theta}) = \frac{f(x_1, \dots, x_n, \hat{\theta})}{f(\hat{\theta})} \quad (1-14)$$

مثال ۱-۱۳: فرض کنید X توزیع دو نقطه‌ای به صورت $P(x) = p^x(1-p)^{1-x}$ دارد
 $(x=0,1)$. تابع احتمال مشترک X_i ها (تابع درستمایی) عبارت است از:

$$\begin{aligned} f(x_1, \dots, x_n, p) &= f(x_1 | p) \dots f(x_n | p) \\ &= p^{x_1} (1-p)^{1-x_1} \dots p^{x_n} (1-p)^{1-x_n} = p^{\sum x_i} (1-p)^{n-\sum x_i} \\ &= p^y (1-p)^{n-y} \quad ; \quad y = \sum_{i=1}^n x_i \end{aligned}$$

از طرف دیگر می‌دانیم که $\hat{p} = \frac{y}{n}$ توزیع دو جمله‌ای دارد.

$$P(\hat{p}) = p\left(\frac{y}{n}\right) = P(y) = C_n^y p^y (1-p)^{n-y}$$

حال $f(x_1, \dots, x_n | \hat{p})$ را می‌نویسیم:

$$\begin{aligned} f(x_1, \dots, x_n | \hat{p}) &= \frac{f(x_1, \dots, x_n, p)}{f(\hat{p})} = \frac{p^y (1-p)^{n-y}}{C_n^y p^y (1-p)^{n-y}} \\ &= \frac{1}{C_n^y} = \frac{1}{C_n^{\sum x_i}} \end{aligned}$$

که بستگی به p ندارد. لذا $\hat{p} = \frac{y}{n}$ یک تخمین‌زننده کافی برای p است.

از طرف دیگر می‌توان شرط (۱-۱۴) را برای $\hat{\theta}$ به صورت زیر نوشت:

$$f(x_1, \dots, x_n, \theta) = g(\hat{\theta}, \theta) h(x_1, \dots, x_n) \quad (1-15)$$

سمت چپ همان تابع درستمایی است. در سمت راست، g تابعی از $\hat{\theta}$ و θ است ولی h فقط تابعی از اطلاعات نمونه است.

مثال ۱-۱۴: X توزیع نرمال با میانگین μ و واریانس σ^2 دارد. با فرض معلوم بودن σ^2 ، برای برآورد μ نمونه‌ای با حجم n انتخاب می‌کنیم. نشان دهید که \bar{X} تخمین‌زننده کافی برای μ است. ابتدا تابع درستمایی را تشکیل می‌دهیم:

$$f(x_1, \dots, x_n, \mu) = \frac{1}{(\sqrt{2\pi})^n \sigma^n} e^{-\frac{\sum (x_i - \mu)^2}{2\sigma^2}}$$

حال تابع درستمایی را تجزیه می‌کنیم. بدین منظور ابتدا عبارت $\sum (x_i - \mu)^2$ را تجزیه می‌کنیم:

$$\sum (x_i - \mu)^2 = \sum [(x_i - \bar{x}) + (\bar{x} - \mu)]^2 = \sum (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2$$

زیرا $\sum (\bar{x} - \mu)^2 = n(\bar{x} - \mu)^2$ و $\sum [(x_i - \bar{x})(\bar{x} - \mu)] = 0$ است. طبق نتیجه فوق، تابع درستمایی را به صورت زیر می‌نویسیم:

$$f(x_1, \dots, x_n, \mu) = \left[\frac{1}{\sqrt{n\pi}\sigma/\sqrt{n}} e^{-\frac{(\bar{x}-\mu)^2}{\sigma^2/n}} \right] \left[\frac{1}{(\sqrt{n\pi})^{n-1} \sqrt{n}\sigma^{n-1}} e^{-\frac{\sum (x_i - \bar{x})^2}{\sigma^2}} \right]$$

درست است؛ گروه اول تابعی از \bar{X} و μ است که همان $g(\bar{X}, \mu)$ می‌باشد و گروه دوم فقط تابعی از X_i ها (اطلاعات نمونه) است که تابعی از μ نیست. بنابراین، \bar{X} تخمین‌زننده کافی برای μ است.

۴-۵-۱ تخمین فاصله‌ای

آنچه تاکنون بحث شد معروف به «تخمین نقطه‌ای» است. این روش، راجع به اینکه تخمین به‌دست آمده تا چه اندازه قابل اطمینان است، بحثی نمی‌کند. در «تخمین فاصله‌ای» برای هر پارامتر، دامنه‌ای به‌دست می‌آید که همراه با یک احتمال است. این احتمال بیانگر سطح اطمینانی است که به فاصله مذکور داریم. بدین لحاظ به آن «فاصله اطمینان» گفته می‌شود. مثلاً اگر با احتمال ۹۵ درصد این فاصله را بسازیم به آن «فاصله اطمینان ۹۵ درصدی» می‌گویند. برای به‌دست آوردن تخمین فاصله‌ای برای پارامتر θ با توجه به اینکه $\hat{\theta}$ تخمین‌زننده θ است، احتمال زیر را تعریف می‌کنیم:

$$P(|\hat{\theta} - \theta| < \varepsilon) = 1 - \alpha \quad (1-16)$$


$1 - \alpha$ بیانگر سطح اطمینان می‌باشد. احتمال فوق را به صورت زیر می‌نویسیم:

$$\begin{aligned} P(-\varepsilon < \hat{\theta} - \theta < \varepsilon) &= 1 - \alpha \\ P(\hat{\theta} - \varepsilon < \theta < \hat{\theta} + \varepsilon) &= 1 - \alpha \end{aligned} \quad (1-17)$$

بنابراین فاصله $(\hat{\theta} - \varepsilon, \hat{\theta} + \varepsilon)$ با احتمال $1 - \alpha$ پارامتر θ را در بر خواهد گرفت. توجه شود که فاصله $(\hat{\theta} - \varepsilon, \hat{\theta} + \varepsilon)$ یا به‌طور خلاصه $\hat{\theta} \pm \varepsilon$ را «تخمین‌زننده فاصله‌ای» می‌گوییم. زیرا $\hat{\theta}$ تابعی از متغیرهای تصادفی است. مقدار حاصل از تخمین‌زننده فاصله‌ای را «تخمین فاصله‌ای» می‌گوییم.

ε نقش مهمی در تعیین طول فاصله اطمینان دارد. طول فاصله اطمینان برابر با 2ε است، زیرا تفاضل حد بالا $(\hat{\theta} + \varepsilon)$ و حد پایین $(\hat{\theta} - \varepsilon)$ را نشان می‌دهد. اما برای تعیین ε الزاماً باید رابطه $\hat{\theta}$ را با یکی از توزیع‌های شناخته شده پیدا کنیم تا بتوان از جداول آنها استفاده نمود. به عنوان مثال یکی از توزیع‌های شناخته شده، توزیع نرمال استاندارد است. برای Z می‌توان احتمال زیر را تعریف نمود:

$$P(-Z_{\frac{\alpha}{2}} \leq Z \leq Z_{\frac{\alpha}{2}}) = 1 - \alpha \quad \text{یا} \quad P(|Z_{\bar{X}}| < Z_{\frac{\alpha}{2}}) = 1 - \alpha \quad (1-18)$$



نمودار ۳: توزیع نرمال و تخمین فاصله‌ای

به عنوان مثال، اگر بخواهیم برای میانگین جامعه نرمال (μ) تخمین فاصله‌ای بسازیم، از \bar{X} استفاده می‌کنیم که استاندارد شده آن $Z = (\bar{X} - \mu) / (\frac{\sigma}{\sqrt{n}})$ است. به جای Z قرار داده و آن را ساده می‌کنیم:

$$P\left(-Z_{\frac{\alpha}{2}} < \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} < Z_{\frac{\alpha}{2}}\right) = 1 - \alpha \Rightarrow P\left(-Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu < Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

بنابراین، $\varepsilon = Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}$ است و تخمین فاصله‌ای برابر است با:

$$P\left(\bar{X} - Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

و یا

$$\left(\bar{X} - Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{X} + Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right)$$

۶-۱ آزمون فرضیه

آزمون فرضیه در مورد توزیع متغیر تصادفی و پارامترهای آن بحث می‌کند. این آزمون ممکن است راجع به نوع توزیع (مثلاً نرمال بودن و...) باشد یا راجع به پارامترهای این توزیع و یا مقایسه برخی از ویژگی‌های دو یا چند متغیر تصادفی باشد. هر آزمون فرضیه‌ای دارای سه مرحله است:

۱- طرح فرضیه: فرضیه‌های آماری معمولاً به صورت دو فرضیه مطرح می‌شوند: یکی فرضیه صفر (H_0) و دیگری فرضیه رقیب (H_1) می‌باشد. به عنوان مثال فرضیه صفر بیانگر آن است که نرخ بیکاری (p) برابر با $0/2$ است، اما فرضیه رقیب می‌گوید که نرخ بیکاری $0/15$ می‌باشد. این فرضیه‌ها به صورت زیر نوشته می‌شوند:

$$H_0: p = 0/2$$

$$H_1: p = 0/15$$

اما می‌توان هر یک از حالات زیر را به عنوان فرضیه صفر و رقیب در نظر گرفت:

$$\begin{array}{lllll} H_0: p = 0/2 & H_0: p = 0/2 & H_0: p = 0/2 & H_0: p \geq 0/2 & H_0: p \leq 0/2 \\ H_1: p > 0/2 & H_1: p < 0/2 & H_1: p \neq 0/2 & H_1: p < 0/2 & H_1: p > 0/2 \end{array}$$

معمولاً در طرح فرضیه‌ها، کل مقادیر مربوط به یک پارامتر را به دو قسمت تقسیم می‌کنند که یک قسمت را H_0 و قسمت دیگر را H_1 پوشش می‌دهد.

۲- معیار آزمون یا آماره آزمون: در این مرحله، قواعد و معیارهایی به کار گرفته می‌شود که بر اساس آن بتوان راجع به رد یا عدم رد فرضیه صفر (H_0) تصمیم‌گیری نمود. انتخاب این معیارها معادل با معرفی یک آماره است که بتواند اطلاعاتی در خصوص فرضیه‌ها ارائه نماید. در این خصوص دو نکته را باید در نظر داشت: اولاً این آماره باید با فرضیه مورد نظر ارتباط داشته باشد. مثلاً اگر فرضیه ما راجع به میانگین جامعه است بایستی از میانگین نمونه (\bar{X}) و اگر راجع به

واریانس است بایستی از واریانس نمونه (S^2) استفاده نمود. ثانیاً آماره معرفی شده بایستی با یکی از توزیعهای معروف (Z ، t ، F و χ^2) رابطه داشته باشد تا بتوان از جداول آنها استفاده نمود.^۱

۳- قاعده‌ی تصمیم‌گیری: قاعده تصمیم‌گیری را می‌توان بدین صورت مطرح کرد که اگر آماره معرفی شده به اندازه کافی نزدیک به مقدار تعریف شده در فرضیه H_0 باشد، در این صورت H_0 را رد نمی‌کنیم. اما اگر به اندازه کافی از H_0 دور باشد، آن را رد می‌کنیم. بدین منظور بایستی یک عدد بحرانی تعیین کنیم که بتواند معیاری برای نزدیکی یا دوری از فرضیه H_0 باشد.

مثال ۱-۱۵: فرض کنید از جامعه‌ای نرمال (مثلاً نمرات درس آمار دانشجویان) نمونه‌ای به حجم n انتخاب نموده ایم و می‌خواهیم راجع به میانگین این جامعه (μ) قضاوت کنیم. این آزمون را در سه مرحله انجام می‌دهیم:

۱- فرضیه را مطرح می‌کنیم (فرضیه صفر این است که میانگین نمرات برابر با ۱۴ است):


$$H_0: \mu = 14$$

$$H_1: \mu \neq 14$$

۲- برای قضاوت راجع به این فرضیه میانگین نمونه (\bar{X}) را معرفی می‌کنیم. از طرف دیگر

می‌دانیم که \bar{X} توزیع نرمال با میانگین μ و واریانس $\frac{\sigma^2}{n}$ دارد. بنابراین اگر \bar{X} را استاندارد کنیم به توزیع نرمال استاندارد $Z = (\bar{X} - \mu) / (\sigma / \sqrt{n})$ می‌رسیم. اما اگر σ^2 مجهول باشد، توزیع t به دست می‌آید.

۳- برای تعیین عدد بحرانی یا ناحیه بحرانی از جدول Z یا t استفاده می‌کنیم. به عنوان مثال اگر با احتمال ۰/۰۵ بخواهیم این فرضیه را آزمون کنیم آنگاه $Z_{0.05} = 1/96$ است. نحوه تصمیم‌گیری به صورت زیر است:



خطای نوع اول و نوع دوم

طبق بحث فوق، α درصد احتمال دارد که آماره مورد نظر در ناحیه بحرانی قرار گیرد، ولی می‌تواند همراه با «درست بودن یا غلط بودن H_0 » باشد. اگر H_0 درست باشد و آماره مورد نظر در ناحیه بحرانی قرار گیرد و آن را رد کنیم، آنگاه دچار یک خطا شده‌ایم که معروف به «خطای نوع

^۱ این توزیع‌ها در بخش ۷-۱ معرفی شده‌اند.

اول است. به طور کلی در آزمون فرضیه، دو نوع خطا وجود دارد که معروف به خطای نوع اول و خطای نوع دوم می باشند.

خطای نوع اول: رد H_0 درست یا قبول H_1 غلط

خطای نوع دوم: رد H_1 درست یا قبول H_0 غلط

۱-۷-۱-۲ توزیع های مهم

در بخش های قبلی، متغیرهای تصادفی، تابع احتمال مشترک نمونه (تابع درستنمایی) و تابعی از متغیرهای نمونه را معرفی کردیم. در این بخش برخی از انواع مهم این توابع را معرفی می کنیم که نقش مهمی در آزمون فرضیه و سایر استنتاج های آماری دارند.

۱-۷-۱-۱ توزیع نرمال استاندارد

اگر متغیر تصادفی X دارای توزیع نرمال با میانگین μ و واریانس σ^2 باشد، آنگاه استاندارد شده آن را نرمال استاندارد می گویند که به صورت زیر تعریف می شود:

$$Z = \frac{X - \mu}{\sigma} \sim N(0, 1) \quad (1-19)$$

لذا Z دارای میانگین ۰ و واریانس ۱ بوده و تابع چگالی آن نیز به صورت زیر است:

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}, \quad -\infty < z < +\infty \quad (1-20)$$

برای محاسبه مقادیر توزیع نرمال از جدول توزیع نرمال استاندارد استفاده می شود.

۱-۷-۱-۲ توزیع کای دو

این توزیع که نقش مهمی در استنتاج آماری دارد از مجموع مجذور نرمال استاندارد به دست می آید. بدین منظور فرض کنید از جامعه ای که متغیر تصادفی X توزیع نرمال با میانگین μ و واریانس σ^2 دارد، نمونه ای به حجم n انتخاب می شود. در این صورت هریک از متغیرهای تصادفی نمونه دارای توزیع نرمال هستند و استاندارد شده آنها نیز توزیع نرمال خواهد داشت:

$$X_i \sim N(\mu, \sigma^2) \quad i = 1, \dots, n \Rightarrow Z_i = \frac{X_i - \mu}{\sigma} \sim N(0, 1) \quad (1-21)$$

اگر μ مجهول باشد به جای آن از میانگین نمونه یعنی \bar{X} استفاده می‌شود. حال تابع جدیدی را به صورت زیر تعریف می‌کنیم:

$$Y = Z_1^2 + \dots + Z_n^2 = \sum_{i=1}^n Z_i^2 = \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{\sigma^2} \quad (1-22)$$

با فرض معلوم بودن μ و σ^2 این تابع دارای توزیع خاصی به نام کای دو یا توان دوم کای می‌باشد که آن را با χ_n^2 نشان می‌دهند.^۱ در اینجا n را درجه آزادی می‌گویند و بیانگر تعداد متغیرهایی است که مقادیر خود را بدون هیچ محدودیتی اختیار می‌کنند. اگر در جامعه اصلی میانگین مجهول باشد، آنگاه Y را به صورت زیر تعریف می‌کنیم:

$$Y = Z_1^2 + \dots + Z_n^2 = \sum_{i=1}^n Z_i^2 = \sum_{i=1}^n \left(\frac{X_i - \bar{X}}{\sigma} \right)^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \quad (1-23)$$

این تابع نیز توزیع کای دو دارد. اما درجه آزادی آن $n-1$ است زیرا یک محدودیت به صورت $\sum (X_i - \bar{X}) = 0$ وجود دارد که باعث می‌شود یکی از متغیرها نتواند مقدار خود را آزادانه انتخاب نماید. توزیع χ_k^2 با درجه آزادی k دارای امید ریاضی k و واریانس $2k$ می‌باشد. یکی از نکات مهم در مورد توزیع کای دو، رابطه آن با واریانس نمونه است:

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} = \frac{\sigma^2}{n-1} \sum_{i=1}^n \left(\frac{X_i - \bar{X}}{\sigma} \right)^2 = \frac{\sigma^2}{n-1} \chi_{n-1}^2 \Rightarrow \frac{S^2}{\sigma^2} = \frac{\chi_{n-1}^2}{n-1} \quad (1-24)$$

توزیع χ^2 هم جمع پذیر و هم تجزیه پذیر است. بدین معنی که حاصل جمع دو توزیع کای دو با درجه آزادی‌های k_1 و k_2 دارای توزیع کای دو با درجه آزادی $k_1 + k_2$ می‌باشد. از طرف دیگر

۱- تابع چگالی χ_k^2 با درجه آزادی k که مقادیر آن را با y نشان می‌دهیم عبارت است از:

$$f_{\chi^2}(y) = \frac{1}{2^{\frac{k}{2}} \Gamma\left(\frac{k}{2}\right)} y^{\frac{k}{2}-1} e^{-\frac{y}{2}} ; y > 0$$

در واقع توزیع χ^2 حالت خاصی از توزیع گاما است که در آن، $\alpha = \frac{k}{2}$ و $\beta = \frac{1}{2}$ است.

توزیع کای دو با درجه آزادی k را می توان به دو توزیع کای دو با درجه آزادی های k_1 و k_2 تجزیه نمود به گونه ای که $k = k_1 + k_2$ باشد.

توزیع χ^2 را می توان به صورت ماتریسی نیز به دست آورد. بدین منظور فرض کنید که \mathbf{x} بردار متغیرهای نرمال باشد:

$$\mathbf{x} = \begin{bmatrix} X_1 \\ \vdots \\ X_n \end{bmatrix}, \quad E(X_i) = \mu_i, \quad \text{var}(X_i) = \sigma_i^2, \quad \text{cov}(X_i, X_j) = 0 \quad (1-25)$$

شرط $\text{cov}(X_i, X_j) = 0$ بیانگر استقلال X_i و X_j است. امید ریاضی و واریانس بردار \mathbf{x} عبارت است از:

$$E(\mathbf{x}) = E \begin{bmatrix} X_1 \\ \vdots \\ X_n \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_n \end{bmatrix} = \boldsymbol{\mu} \quad (1-26)$$

$$\begin{aligned} \text{var}(\mathbf{x}) &= E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})'] = E \begin{bmatrix} X_1 - \mu_1 \\ \vdots \\ X_n - \mu_n \end{bmatrix} \begin{bmatrix} X_1 - \mu_1 & \dots & X_n - \mu_n \end{bmatrix} \\ &= \begin{bmatrix} E(X_1 - \mu_1)^2 & \dots & E[(X_1 - \mu_1)(X_n - \mu_n)] \\ \vdots & & \vdots \\ E[(X_n - \mu_n)(X_1 - \mu_1)] & \dots & E(X_n - \mu_n)^2 \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \sigma_n^2 \end{bmatrix} = \boldsymbol{\Omega} \quad (1-27) \end{aligned}$$

بنابراین، $\boldsymbol{\Omega}$ ماتریس قطری است که عنصر نام آن برابر با واریانس X_i است.

با استفاده از محاسبات و نتایج فوق، خواهیم داشت:

$$(\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Omega}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \sim \chi^2 \quad (1-28)$$

$\boldsymbol{\Omega}^{-1}$ برابر است با:

$$\boldsymbol{\Omega}^{-1} = \begin{bmatrix} \frac{1}{\sigma_1^2} & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \frac{1}{\sigma_n^2} \end{bmatrix} \quad (1-29)$$

با جایگذاری به جای $\boldsymbol{\Omega}^{-1}$ و $\mathbf{x} - \boldsymbol{\mu}$ ، خواهیم داشت:

$$\begin{aligned}
 (\mathbf{x}-\boldsymbol{\mu})'\boldsymbol{\Omega}^{-1}(\mathbf{x}-\boldsymbol{\mu}) &= [X_1-\mu_1 \quad \dots \quad X_n-\mu_n] \begin{bmatrix} \frac{1}{\sigma_1^2} & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \frac{1}{\sigma_n^2} \end{bmatrix} \begin{bmatrix} X_1-\mu_1 \\ \vdots \\ X_n-\mu_n \end{bmatrix} \\
 &= \sum_{i=1}^n \left(\frac{X_i-\mu_i}{\sigma_i} \right)^2 = \sum_{i=1}^n Z_i^2 \quad (1-30)
 \end{aligned}$$

بنابراین، عبارت فوق برابر با مجموع مجذور نرمال‌های استاندارد است که توزیع χ^2 خواهد داشت.

۳-۷-۱ توزیع t

توزیع t به صورت زیر تعریف می‌شود:

$$t_k = \frac{Z}{\sqrt{\frac{\chi_k^2}{k}}} \quad (1-31)$$

Z نرمال استاندارد و χ_k^2 نیز توزیع کای دو با درجه آزادی k می‌باشد.

به عنوان مثال اگر از جامعه‌ای نرمال، نمونه‌ای به حجم n انتخاب شود، در این صورت \bar{X} و S^2 عبارتند از:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}, \quad S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$$

حال \bar{X} را استاندارد کرده و S^2 را نیز بر حسب χ^2 می‌نویسیم:

$$Z_{\bar{X}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} = \sqrt{n} \frac{\bar{X} - \mu}{\sigma}, \quad \frac{S^2}{\sigma^2} = \frac{\chi_{n-1}^2}{n-1} \quad (1-32)$$

توجه شود که $E(\bar{X}) = \mu$ و $\text{var}(\bar{X}) = \frac{\sigma^2}{n}$ می‌باشد.

حال توزیع t را تشکیل می‌دهیم:

$$t_{n-1} = \frac{Z_{\bar{X}}}{\sqrt{\frac{\chi^2_{n-1}}{n-1}}} \quad (1-33)$$

با جایگذاری به جای $Z_{\bar{X}}$ و $\frac{\chi^2_{n-1}}{n-1}$ و مرتب نمودن آن خواهیم داشت:

$$t_{n-1} = \frac{\bar{X} - \mu}{\frac{S}{\sqrt{n}}} = \sqrt{n} \frac{\bar{X} - \mu}{S} \quad (1-34)$$

اگر نتیجه به دست آمده را با $Z_X = \sqrt{n} \frac{\bar{X} - \mu}{\sigma}$ مقایسه کنیم مشاهده می شود که t شباهت زیادی به Z دارد و تنها تفاوت آنها در این است که به جای σ (انحراف معیار جامعه) از S (انحراف معیار نمونه) استفاده شده است.

۴-۲-۱ توزیع F

توزیع F کاربردهای بسیاری در مباحث اقتصادسنجی، به ویژه در آزمون فرضیه ها، مقایسه رگرسیون ها و یا مقایسه اثر عوامل مختلف بر یک متغیر دارد. توزیع F از تقسیم دو توزیع کای دو به دست می آید:

$$F_{k_1, k_2} = \frac{\chi^2_{k_1} / k_1}{\chi^2_{k_2} / k_2} \quad (1-35)$$

توزیع F دارای دو درجه آزادی می باشد که یکی مربوط به صورت کسر و دیگری مربوط به مخرج کسر است. با توجه به رابطه χ^2 و S^2 می توان توزیع F را به صورت نسبت واریانس های نمونه نوشت. فرض کنید از دو جامعه، نمونه هایی به حجم n_1 و n_2 انتخاب شود. در این صورت طبق رابطه (۱-۳۲)، روابط زیر را داریم:

$$\frac{S_1^2}{\sigma_1^2} = \frac{\chi^2_{n_1-1}}{n_1-1} \quad \text{و} \quad \frac{S_2^2}{\sigma_2^2} = \frac{\chi^2_{n_2-1}}{n_2-1}$$

با جایگذاری در F و مرتب نمودن آن خواهیم داشت:

$$F_{n_1-1, n_2-1} = \frac{\sigma_2^2 S_1^2}{\sigma_1^2 S_2^2} \quad (1-36)$$

۵-۲-۱ حالت‌های خاص توزیع‌های χ^2 و t و F

حالت‌های خاص توزیع‌های χ^2 ، t و F و همچنین روابط آنها عبارت است از:

۱- اگر درجه آزادی کای دو به سمت بی‌نهایت میل کند، خواهیم داشت:

$$\lim_{k \rightarrow \infty} \frac{\chi_k^2}{k} = 1 \quad (1-37)$$

۲- اگر درجه آزادی کای دو بزرگتر از ۳۰ باشد، می‌توان از توزیع نرمال به‌عنوان تقریب

مناسبی برای آن استفاده نمود:

$$\chi_k^2 \sim N(k, \sqrt{2k}) \quad (1-38)$$

اما چون توزیع کای دو به‌کندی به توزیع نرمال گرایش دارد از تبدیل فیشر استفاده می‌شود که

طبق آن رابطه زیر برقرار است:

$$\sqrt{2\chi_k^2} \sim N(\sqrt{2k-1}, 1)$$

بنابر این، استاندارد شده آن عبارت است از:

$$Z = \frac{\sqrt{2\chi_k^2} - \sqrt{2k-1}}{1} = \sqrt{2\chi_k^2} - \sqrt{2k-1} \sim N(0, 1) \quad (1-39)$$

مقادیر توزیع کای دو برابر است با:

$$\sqrt{2\chi_k^2} = Z + \sqrt{2k-1} \Rightarrow \chi_k^2 = \frac{1}{2} \left(Z + \sqrt{2k-1} \right)^2 \quad (1-40)$$

به‌عنوان مثال، مقدار ۵ درصدی توزیع کای دو با درجه آزادی $k=40$ برابر است با:

$$\chi_{0.05, 40}^2 = \frac{1}{2} \left(Z_{0.05} + \sqrt{2(40)-1} \right)^2 = \frac{1}{2} (1.64 + \sqrt{79})^2 = 55.42$$

که مقدار دقیق $\chi_{0.05, 40}^2$ با استفاده از جدول کای دو برابر با ۵۵/۸ می‌باشد.

۳- اگر در توزیع F درجه آزادی مخرج، بی‌نهایت باشد خواهیم داشت:

$$F_{k_1, \infty} = \frac{\chi_{k_1}' / k_1}{1} = \frac{\chi_{k_1}'}{k_1} \quad (1-41)$$

اگر درجه آزادی صورت بی نهایت باشد، خواهیم داشت:

$$F_{\infty, k_1} = \frac{1}{\chi_{k_1}' / k_1} = \frac{k_1}{\chi_{k_1}'} = \frac{1}{F_{k_1, \infty}} \quad (1-42)$$

۴- اگر در توزیع F ، درجه آزادی صورت برابر با ۱ باشد، آنگاه توزیع F با مجذور توزیع t برابر است:

$$F_{1, k_1} = \frac{\chi_{k_1}' / 1}{\chi_{k_1}' / k_1} = \frac{Z'}{\chi_{k_1}' / k_1} = t_{k_1}' \quad (1-43)$$

۸-۱ انواع داده‌ها

داده‌های مورد استفاده در مباحث اقتصادی و مالی را می‌توان به سه دسته کلی تقسیم نمود: سری‌های زمانی، داده‌های مقطعی و داده‌های پانل (ترکیبی).

داده‌های سری زمانی مربوط به یک دوره زمانی معین است که ممکن است سالانه، فصلی، ماهانه، هفتگی، روزانه و یا حتی ساعتی و کمتر باشد.

داده‌های مقطعی بیانگر اطلاعات مربوط به یک متغیر در یک زمان معین می‌باشد. مانند مصرف نان در گروه‌های درآمدی مختلف در سال ۱۳۸۰، بازده سهام شرکت‌های مختلف در سال ۱۳۸۸، تغییرات قیمت سهام شرکت‌های مختلف در ۱۳۸۸/۱۰/۲۰ و رشد اقتصادی کشورهای مختلف در سال ۲۰۱۰.


داده‌های ترکیبی یا پانل، ترکیبی از داده‌های سری زمانی و مقطعی است، یعنی هم مقطع و هم زمان را شامل می‌شود. مانند رشد اقتصادی کشورهای مختلف در دوره ۲۰۱۰-۱۹۸۰، قیمت سهام شرکت‌های مختلف در دوره ۱۳۸۵-۱۳۸۰. اگر طول دوره را با T و تعداد مقطع‌ها را با n نشان دهیم، کل مشاهدات برابر با nT خواهد بود.

۹-۱ آشنایی مقدماتی با نرم‌افزار Eviews

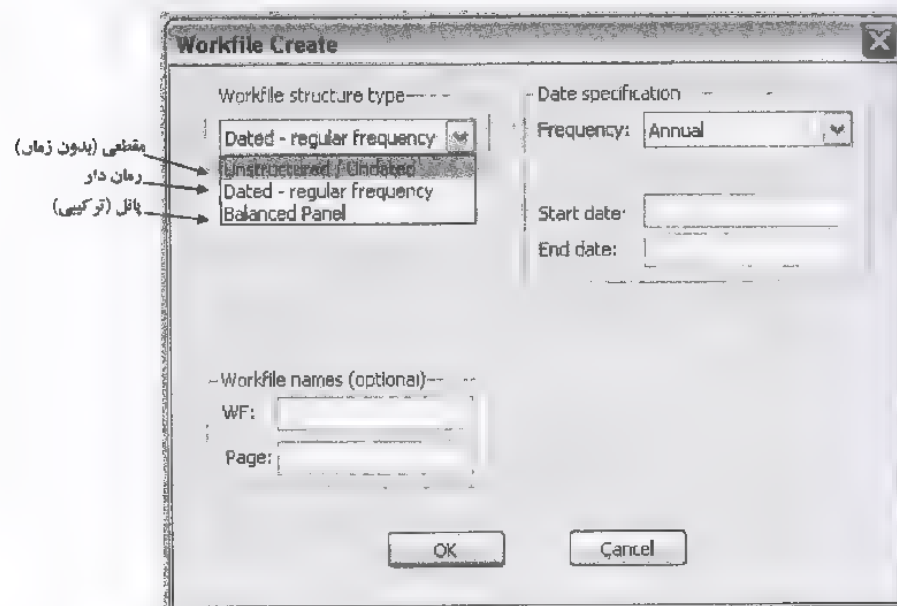
Eviews از جمله نرم‌افزارهایی است که کار با آن بسیار ساده است. در اینجا نکات اولیه جهت کار با Eviews7 را ارائه می‌کنیم. سایر نکات در فصول بعدی همراه با مباحث اقتصادسنجی ارائه خواهد شد.

ایجاد فایل کاری (Workfile)

بعد از نصب Eviews و اجرای آن، پنجره Eviews باز می‌شود که به شکل زیر بوده و از این به بعد آن را پنجره اصلی می‌گوییم.



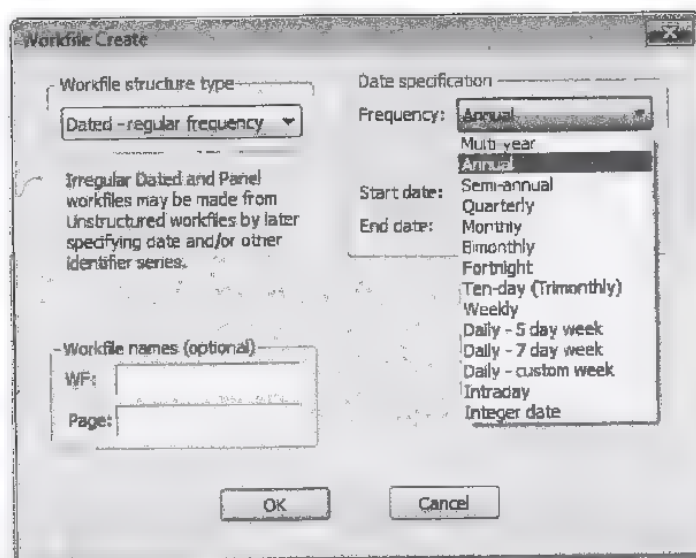
برای ایجاد فایل کاری، ابتدا در پنجره اصلی از طریق منوی File گزینه New را انتخاب می‌کنیم که به دنبال آن پنجره فایل کاری تحت عنوان Workfile Create باز می‌شود.



در سمت چپ این پنجره باید نوع داده‌ها را مشخص کنیم که آیا مقطعی (بدون زمان) یا سری زمانی (زمان‌دار) است و یا پانل (ترکیبی) می‌باشد. در مورد داده‌های ترکیبی در فصول بعدی بحث خواهیم کرد.

اگر داده‌ها به صورت مقطعی باشد، ابتدا گزینه Unstructured/Undated را انتخاب کرده و سپس تعداد مشاهدات را در قسمت Observations که در سمت راست نمایان می‌شود، وارد می‌کنیم.

اگر داده‌ها به صورت سری زمانی باشد، ابتدا گزینه Dated-regular frequency را انتخاب کرده و سپس در سمت راست، بر حسب نوع داده‌ها یکی از موارد سالانه، فصلی، ماهانه، هفتگی و روزانه و ... را انتخاب می‌کنیم.



برخی از این موارد به صورت زیر می‌باشد:

داده‌های سالانه: در سمت راست، گزینه Annual را انتخاب می‌کنیم. اگر سال شروع ۱۳۵۰ و سال پایان ۱۳۸۰ باشد، زمان شروع و پایان را به صورت زیر وارد می‌کنیم:

Start date	End date
1350	1380

داده‌های فصلی: در سمت راست، گزینه Quarterly را انتخاب می‌کنیم. اگر زمان شروع، تابستان ۱۳۵۰ و زمان پایان، بهار ۱۳۹۰ باشد، آن را به صورت زیر وارد می‌کنیم:

Start date	End date
1350:2	1390:1

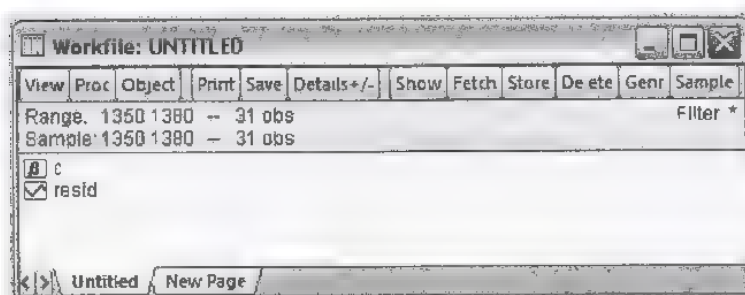
داده‌های ماهانه: در سمت راست، گزینه Monthly را انتخاب می‌کنیم. اگر زمان شروع، بهمن ۱۳۵۰ و زمان پایان، خرداد ۱۳۹۰ باشد، آن را به صورت زیر وارد می‌کنیم:

Start date	End date
1350:11	1390:3

داده‌های هفتگی: در سمت راست گزینه Weekly را انتخاب می‌کنیم. در اینجا ابتدا هفته و سپس سال را وارد می‌کنیم. برای وارد نمودن شماره هفته، تاریخ شروع آن در ماه مورد نظر را وارد می‌کنیم (سال: روز: ماه). به عنوان مثال 11:5:1380 بیانگر هفته‌ای است که شروع آن پنجم بهمن ۱۳۸۰ می‌باشد.

داده‌های روزانه: برای داده‌های روزانه، ابتدا یکی از گزینه‌های Daily یا Daily(5 Day Weeks) را انتخاب کرده و سپس به ترتیب ماه، روز و سال مورد نظر را وارد می‌کنیم (سال: روز: ماه).

بعد از مشخص نمودن نوع داده‌ها و انتخاب OK، پنجره دیگری به نام فایل کاری (Workfile) باز می‌شود. در این پنجره، حرف c بیانگر پارامترهای مدل تخمینی است و عبارت resid بیانگر باقیمانده‌ها یا خطاهای مدل تخمینی است که در تخمین معادلات مورد استفاده بوده و بعداً راجع به آن بحث خواهیم کرد.



ورود داده‌ها

برای ورود داده‌ها می‌توان مستقیماً هر متغیری را ایجاد کرده و داده‌های آن را به صورت دستی وارد نمود. به عنوان مثال برای ورود داده‌های X ابتدا در پنجره فرمان، عبارت data x را نوشته و با زدن کلید Enter پنجره زیر را باز می‌کنیم.

obs	obs	Date - Frequency	Series
1345	1345	1345	NA
1346	1346	1346	NA
1347	1347	1347	NA
1348	1348	1348	NA
1349	1349	1349	NA
1350	1350	1350	NA
1351	1351	1351	NA
1352	1352	1352	NA
1353	1353	1353	NA
1354	1354	1354	NA
1355	1355	1355	NA
1356	1356	1356	NA
1357	1357	1357	NA
1358	1358	1358	NA
1359	1359	1359	NA
1360	1360	1360	NA

در این پنجره در مقابل هر سال داده‌های آن سال را وارد و در پایان، با بستن این پنجره، نام متغیر مورد نظر (x) در فایل کاری نمایان می‌شود. همچنین برای ورود داده‌ها می‌توان آنها را از نرم‌افزارهای دیگری مانند Excel وارد Eviews نمود.

ایجاد متغیرهای جدید

با فرمان `genr` می‌توان هر متغیر جدیدی را بر اساس متغیرهای موجود، ایجاد نمود. مثلاً اگر z برابر با x^2 باشد می‌توان در سطر فرمان از فرمان `genr z=x^2` استفاده نمود. سایر متغیرها را به‌عنوان نمونه می‌توان به‌صورت زیر ایجاد نمود:

$$\text{جمع} \quad u=x+y$$

$$\text{تقسیم} \quad u=x/5, \quad u=x/y$$

$$\text{لگاریتم} \quad u=\log(x)$$

$$\text{نمایی} \quad u=\exp(x)$$

وقفه‌ها و تفاضل‌ها

اگر متغیر x_t بیانگر مقدار x در سال t باشد، در نرم‌افزار Eviews با x نشان داده می‌شود. ولی برای x_{t-1} که مقدار x را در سال در سال $t-1$ (سال گذشته) و یا مقدار x را با یک وقفه بیان می‌کند،

در Eviews با $x(-1)$ نشان داده می‌شود. همچنین برای دو وقفه (دو سال قبل) از $x(-2)$ استفاده می‌شود. علاوه بر این، برای سال‌های بعد از t مانند $t+1$ و $t+2$ از $x(1)$ و $x(2)$ استفاده می‌شود. طبق تعاریف فوق برای محاسبه تفاضل مرتبه اول (تغییرات مرتبه اول) از $x-x(-1)$ استفاده می‌شود. اگر تفاضل مرتبه اول x را با dx نشان دهیم، در این صورت از فرمان زیر استفاده می‌کنیم:

$$\text{genr } dx=x-x(-1) \quad \text{یا} \quad \text{genr } dx=d(x)$$

همچنین برای محاسبه نرخ رشد x ، یعنی gx ، از فرمان زیر استفاده می‌کنیم:

$$\text{genr } gx=(x-x(-1))/x(-1)=d(x)/x(-1)$$

تغییر نام متغیرها

برای تغییر نام متغیرها از فرمان «تغییر نام» استفاده کنیم که علامت اختصاری آن r می‌باشد. مثلاً برای تغییر نام x به y به صورت زیر عمل می‌کنیم:

$$r \ x \ y$$

متغیر زمان

در مواردی نیاز به «متغیر روند» داریم. به عنوان مثال اگر داده‌های ما از سال ۱۳۵۱ تا ۱۳۹۰ باشد، متغیر روند که با t نشان می‌دهیم از ۱ برای سال ۱۳۵۱ شروع شده و تا ۴۰ برای سال ۱۳۹۰ ادامه می‌یابد. مانند هر متغیر معمولی، اگر مقادیر متغیر روند را با t نشان دهیم، آن را با فرمان «data» ایجاد می‌کنیم. اما در Eviews می‌توان عبارت $@trend$ را برای متغیر روند استفاده نمود.

اصلاح داده‌های وارد شده


همان طور که قبلاً دیدیم برای وارد نمودن داده‌های متغیر x از فرمان «data x» استفاده می‌کنیم. حال اگر در وارد نمودن داده‌ها، اشتباهی رخ داده باشد مجدداً فرمان «data x» را اجرا کرده و اصلاحات مورد نظر را انجام می‌دهیم.

مشاهده داده‌های وارد شده


برای مشاهده داده‌های وارد شده از فرمان show استفاده می‌شود. مثلاً برای مشاهده مقادیر x و y از فرمان «show x y» استفاده می‌کنیم.

نمودارها

در Eviews امکان ترسیم نمودارهای مختلف وجود دارد. مثلاً برای ترسیم داده‌های سری زمانی از فرمان `plot` استفاده می‌شود. به‌عنوان مثال برای ترسیم داده‌های x از فرمان `plot x` و برای ترسیم همزمان داده‌های x و y از فرمان `plot x y` استفاده می‌کنیم.



در بسیاری از موارد نیاز به ترسیم داده‌های یک متغیر در مقابل دیگری داریم. در این صورت می‌توان از فرمان `scat` استفاده نمود. برای رسم داده‌های y در مقابل x (روی محور عمودی و x روی محور افقی) از فرمان `scat x y` استفاده می‌کنیم. با اجرای این فرمان، نمودار پراکندگی ترسیم می‌گردد.



تغییر دوره زمانی

در بالای فایل کاری، عبارت دامنه (Range) و نمونه (Sample) را ملاحظه می‌کنیم. به عنوان مثال اگر داده‌های ما شامل دوره ۱۳۵۰ تا ۱۳۸۰ باشد، در این صورت دامنه و نمونه شامل دوره ۱۳۵۰ تا ۱۳۸۰ می‌باشد. اگر بخواهیم دامنه را تا سال ۱۳۹۰ گسترش دهیم در سطر فرمان از فرمان «range 1350 1390» استفاده می‌کنیم. معمولاً نیاز کمتری به تغییر دامنه پیدا می‌کنیم. موارد استفاده از تغییر نمونه بسیار زیاد است. به عنوان مثال، اگر بخواهیم فقط با داده‌های دوره ۱۳۵۰ تا ۱۳۷۰ کار کنیم در صورت دوره نمونه را با فرمان «smpl 1350 1370» تغییر می‌دهیم. این فرمان را می‌توان برای هر دوره دیگری نیز به کار برد. به عنوان نمونه اگر بخواهیم نمونه ما شامل سال ۱۳۵۷ نباشد از فرمان «smpl 1350 1356 1358 1380» استفاده می‌کنیم.

مسائل

۱- یک فایل کاری در Eviews بسازید و داده‌های زیر را وارد کنید.

سال	X	Y	Z
۱۳۵۱	۱	۵۰	-۱۰
۱۳۵۲	۱	۴۸	-۸
۱۳۵۳	۲	۴۶	-۹
۱۳۵۴	۲	۵۰	۶
۱۳۵۵	۳	۴۲	-۵
۱۳۵۶	۳	۴۴	۵
۱۳۵۷	۴	۴۰	-۸
۱۳۵۸	۶	۴۰	-۲
۱۳۵۹	۵	۳۸	۱
۱۳۶۰	۸	۳۶	۱
۱۳۶۱	۱۰	۳۵	۲
۱۳۶۲	۱۰	۳۵	۴
۱۳۶۳	۱۲	۳۰	۴
۱۳۶۴	۱۴	۲۸	۵
۱۳۶۵	۱۳	۳۶	۶
۱۳۶۶	۱۶	۲۵	۶
۱۳۶۷	۱۸	۲۵	۷
۱۳۶۸	۱۸	۲۴	۸
۱۳۷۰	۲۰	۲۲	۹
۱۳۷۱	۲۰	۲۰	۱۰
۱۳۷۲	۲۲	۲۲	۱۰
۱۳۷۳	۲۳	۱۸	۱۲
۱۳۷۴	۲۲	۱۸	۱۰
۱۳۷۵	۲۵	۱۶	۱۵
۱۳۷۶	۲۷	۱۶	۱۵
۱۳۷۷	۳۰	۱۴	۱۸
۱۳۷۸	۳۰	۱۲	۲۰
۱۳۷۹	۳۳	۱۲	۲۰
۱۳۸۰	۳۳	۱۰	۲۲

۲- در مسئله ۱، نمودار سری‌های زمانی را برای X ، Y و Z ترسیم کنید.

۳- در مسئله ۱، Y را در مقابل Z رسم کنید.

۴- در مسئله ۱، تغییرات Y و Z را حساب کرده و سپس تغییرات Y را در مقابل تغییرات Z رسم کنید. چه تفاوتی با نمودار مسئله ۳ مشاهده می‌کنید.

۵- در مسئله ۱ نرخ رشد X ، Y و Z را حساب کنید و نمودار آنها را ترسیم کنید.

۶- اگر X توزیع نرمال با تابع چگالی $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ داشته باشد، ضرایب μ و σ^2 را با روش گشتاورها برآورد کنید.

۷- X توزیع هندسی با تابع احتمال $P(x) = p(1-p)^{x-1}$ دارد. ضریب p را با روش گشتاورها برآورد کنید.

۸- X توزیع نرمال با تابع چگالی $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ دارد. ضرایب μ و σ^2 را با روش حداکثر درستنمایی برآورد کنید.

۹- X توزیع هندسی با تابع احتمال $P(x) = p(1-p)^{x-1}$ دارد. ضریب p را با روش حداکثر درستنمایی برآورد کنید.

۱۰- در مسئله ۴، خاصیت بدون تورش بودن تخمین‌زننده‌های حداکثر درستنمایی را بررسی کنید.

۱۱- در مسئله ۳، آیا تخمین‌زننده حداکثر درستنمایی، حد پایین نامساوی راثو-کرامر را تأمین می‌کند.

۱۲- در مسئله ۳، تخمین‌زننده σ^2 که به صورت $\frac{\sum (X_i - \bar{X})^2}{n}$ به دست می‌آید، آیا در مقایسه با تخمین‌زننده بدون تورش $S^2 = \frac{\sum (X_i - \bar{X})^2}{n-1}$ کارایی بیشتر دارد.

۱۳- در مسئله ۴، آیا تخمین‌زننده p حد پایین نامساوی راثو-کرامر را تأمین می‌کند.

۱۴- خاصیت سازگاری را برای تخمین‌زننده‌های μ و σ^2 در مسئله ۸ بررسی کنید.

۱۵- خاصیت سازگاری را برای تخمین‌زننده p در مسئله ۹ بررسی کنید.

۱۶- اگر u توزیع نرمال با میانگین صفر و واریانس σ^2 داشته باشد، ثابت کنید که $\frac{u'u}{\sigma^2}$ توزیع کای دو دارد که $u' = (u_1, u_2, \dots, u_n)$ است.

۱۷- در مسئله ۱۶ ثابت کنید که نسبت $\frac{\bar{u}}{\sqrt{u'u}} \sqrt{n-1}$ توزیع t با درجه آزادی $n-1$ دارد (\bar{u} میانگین u است).

۱۸- ثابت کنید که $F_{n,n} = t_n^2$ است.

۱۹- X توزیع نمایی به صورت $f(x) = \frac{1}{\beta} e^{-\frac{x}{\beta}}$ دارد.

الف) با استفاده از روش گشتاورها، تخمین‌زننده β را به دست آورید.

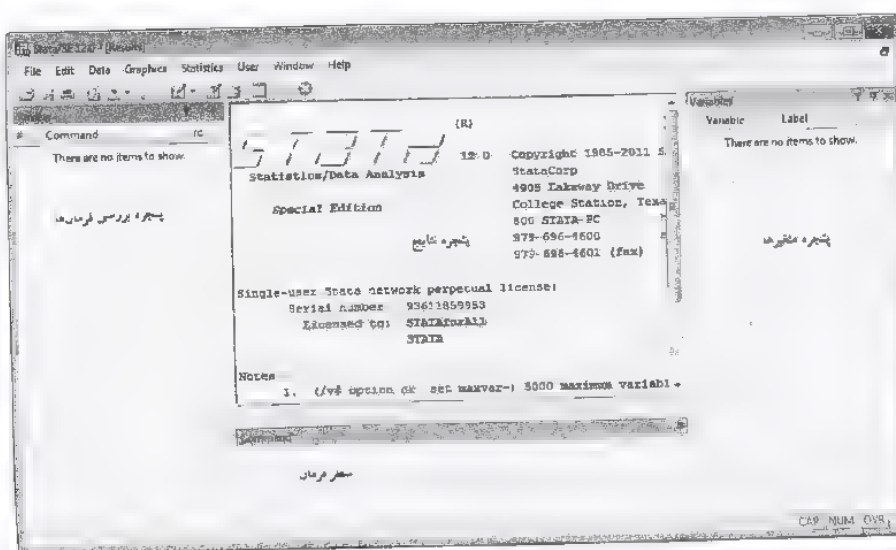
ب) ثابت کنید که تخمین‌زننده حداکثر درستنمایی برای β برابر با \bar{X} است.

ج) آیا تخمین‌زننده حداکثر درستنمایی، شرایط بدون تورش، سازگاری، حد پایین نامساوی راثو-کرامر و کفایت را تأمین می‌کند.

ضمیمه فصل ۱: مروری بر نرم‌افزار Stata

معرفی بخش‌های اولیه Stata

- بعد از اجرای نرم‌افزار Stata، ابتدا پنجره زیر را مشاهده خواهید کرد که دارای چهار قسمت است:
- ۱- سطر فرمان که می‌توان فرمان‌های مختلف را در آن تایپ کرد.
 - ۲- پنجره بررسی فرمان‌های قبلی است که فرمان‌های قبلی را نشان می‌دهد.
 - ۳- پنجره متغیرها که نام متغیرهای موجود در فایل داده‌ها را نشان می‌دهد.
 - ۴- پنجره نتایج که نتایج حاصل از اجرای فرمان‌ها را نشان می‌دهد.



نوار بالای پنجره فوق، منوهای اصلی را نشان می‌دهد که هر یک از آنها کارکردهای خاص خود را دارد که در قسمت‌های بعدی به آنها اشاره خواهیم کرد.

ایجاد فایل کاری و ورود داده‌ها

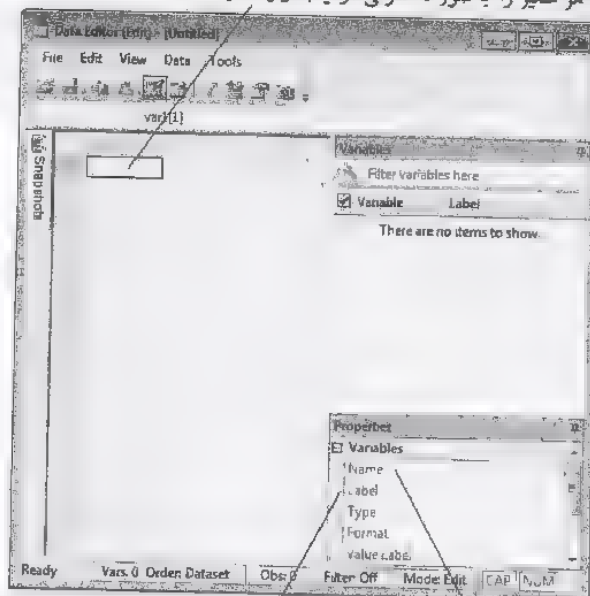
ابتدا با پستی یک فایل گازی وارد نمودن داده‌ها ایجاد نماییم. بدین منظور مسیر زیر را انتخاب می‌کنیم:

Data → Data editor

پنجره data editor برای ورود داده‌ها باز می‌شود. در این پنجره، هر ستون برای یک متغیر می‌باشد. با کلیک روی سطر اول هر ستون می‌توانید داده‌های متغیر مورد نظر را وارد کنید. داده‌ها را می‌توان به صورت دستی یا از برنامه‌های دیگر مانند excel یا eviews ... کپی نمود.

در این پنجره، delete برای حذف متغیر، hide برای پنهان کردن نام متغیر، restore برای ذخیره تغییرات انجام شده می‌باشد. در اینجا لازم است متغیر زمان را تعریف کنیم که برای سری‌های زمانی بیانگر زمان یا دوره نمونه است.

داده‌های هر متغیر را به صورت ستونی در اینجا وارد کنید



روی Label دوبار کلیک کرده
و متغیر مورد نظر را توصیف کنید

در اینجا دو یا کلیک کرده،
نام دلخواه را برای متغیر
مورد نظر انتخاب کنید

علاوه بر شیوه فوق، می‌توان برای تغییر نام متغیره از فرمان زیر استفاده نمود:

```
rename var1 y یا ren var1 y
```

اجرای فرمان فوق، نام متغیر var1 را به y تغییر می‌دهد.

مشاهده و اصلاح داده‌های وارد شده

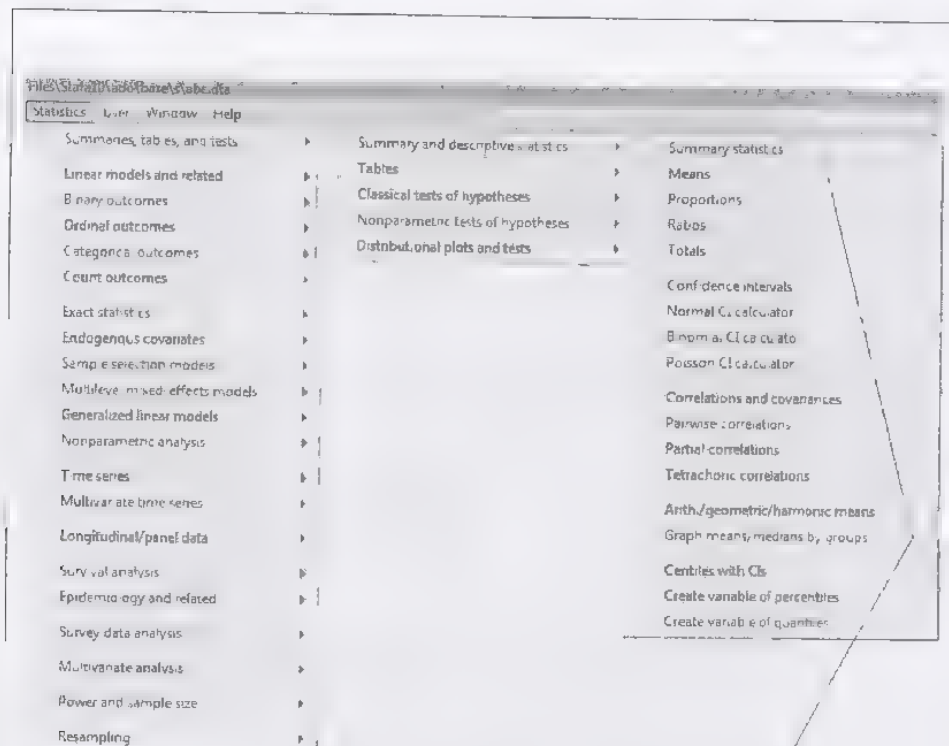
برای مشاهده داده‌های وارد شده می‌توان از مشابه وارد نمودن داده‌های جدید، عمل نمود و از طریق Data Editor داده‌ها را مشاهده و اصلاح نمود.

همچنین می‌توان برای مشاهده داده‌ها از فرمان زیر استفاده نمود:

```
list y x z
```

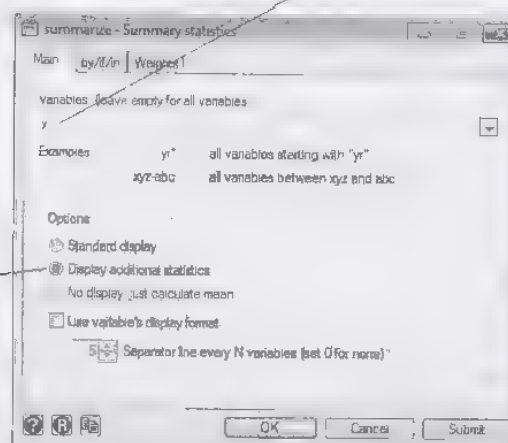
توصیف کلی داده‌های یک متغیر

برای هر متغیر می‌توان شاخص‌های مختلفی از قبیل میانگین، واریانس و غیره را محاسبه نمود. بدین منظور به صورت زیر عمل می‌کنیم:



پنجره زیر باز می‌شود که نام متغیر مورد نظر را در اینجا وارد می‌کنیم

برای گرفتن جزئیات بیشتر



محاسبات متغیر y به صورت زیر نشان داده می شود:

y				تعداد مشاهدات	
Percentiles	Smallest			obs	20
1%	11			Sum of wgt.	20
5%	11			Mean	18.3
10%	11.5			Std. Dev.	5.582869
25%	13.5			Variance	31.16842
50%	17.5	Largest	24	Skewness	.2422
75%	23.5		25	Kurtosis	1.704557
90%	26		27		
95%	27.5		28		
99%	28				

نتایج فوق را می توان با فرمان ساده sum y, detail نیز به دست آورد. علاوه بر این، اگر یکی از فرمان های زیر را اجرا کنیم، خلاصه ای از وضعیت متغیر مورد نظر ارائه می شود:

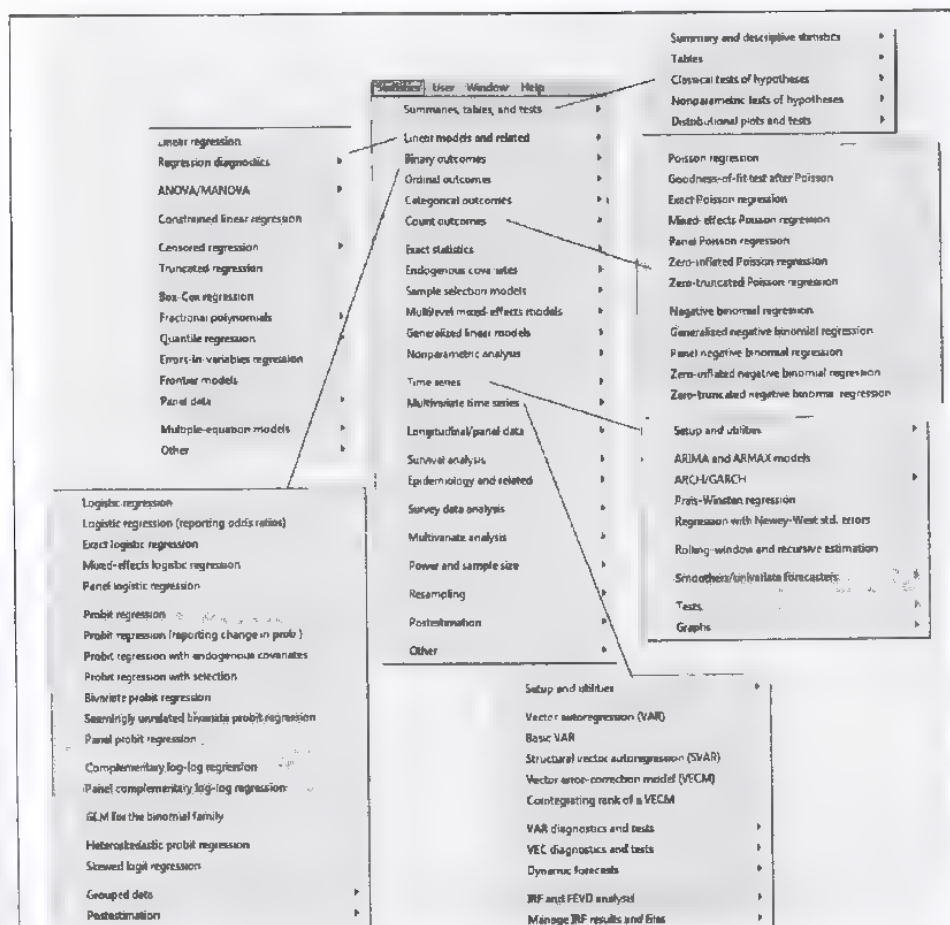
Summarize ip یا summ ip یا sum ip

که نتایج به صورت زیر نشان داده شده می شود:

sum ip					
variable	obs	Mean	Std. Dev.	Min	Max
ip	21	22847.13	12319.65	4873.2	52803.6
نام متغیر	تعداد مشاهدات	میانگین	انحراف معیار	حداقل	حداکثر

منوی Statistics

محاسبات آماری و روش های مربوطه، معدداً در گزینه های این منو قرار دارد. هر یک از قسمت های این منو، جزئیات زیادی دارد که در قسمت های بعدی، به آنها اشاره خواهیم کرد. برخی از کارکردهای آن در نمودار زیر نشان داده شده است.



ایجاد متغیر جدید

با استفاده از متغیرهای موجود می‌توان متغیرهای جدیدی را تعریف نمود. بدین منظور از فرمان `gen` استفاده می‌شود:

```
gen u=y+10
```

```
gen v=x+y
```

```
gen w=x^2
```

```
gen ly=log(y)
```

```
gen q=x if x>8
```

آخری، متغیر `q` را برآیند `x` می‌دهد ولی به‌ازای مقادیر بزرگتر از هشت، توجه شود که در این حالت، مقدار `q` در مواردی که `x` کوچکتر از ۱۰ است، موجود نمی‌باشد. همچنین فرمان‌های دیگری برای سایر محاسبات وجود دارد که به‌منوان مثال برای محاسبه لگاریتم از فرمان زیر استفاده می‌شود:

```
gen y=log(x)
```

متغیر زمان

متغیر زمان برای داده‌های سالانه: از سال ۱۳۵۰ تا ... با فرمان زیر حساب می‌شود:

```
gen t=1350+_n-1
```

متغیر زمان برای داده‌های فصلی (۳ ماهه): دو فرمان زیر را به‌دنبال هم اجرا می‌کنیم:

```
gen t=tq(1350q1)+_n-1
format t %tq
```

متغیر زمان برای داده‌های ماهانه: دو فرمان زیر را به‌دنبال هم اجرا می‌کنیم:

```
gen t=tm(1350m1)+_n-1
format t %tm
```

متغیر زمان برای داده‌های هفتگی: دو فرمان زیر را به‌دنبال هم اجرا می‌کنیم:

```
gen t=tw(1350w1)+_n-1
format t %tw
```

متغیر زمان برای داده‌های روزانه: دو فرمان زیر را به‌دنبال هم اجرا می‌کنیم:

```
gen t=td(23dec1985)+_n-1
format t %td
```

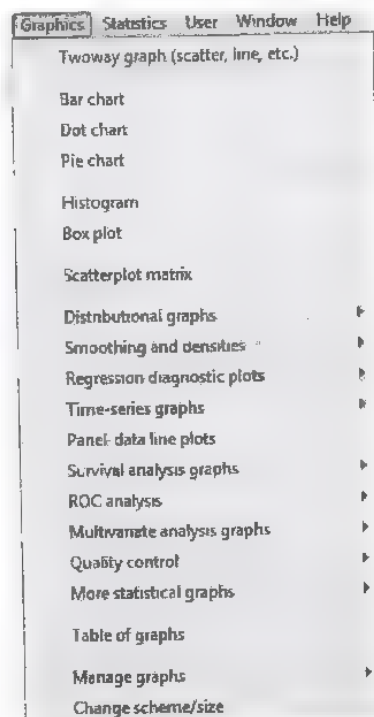
بعد از ایجاد متغیر زمان، فرمان زیر را اجرا می‌کنیم تا متغیر t به‌عنوان زمان در نظر گرفته شود:

```
tsset t
```

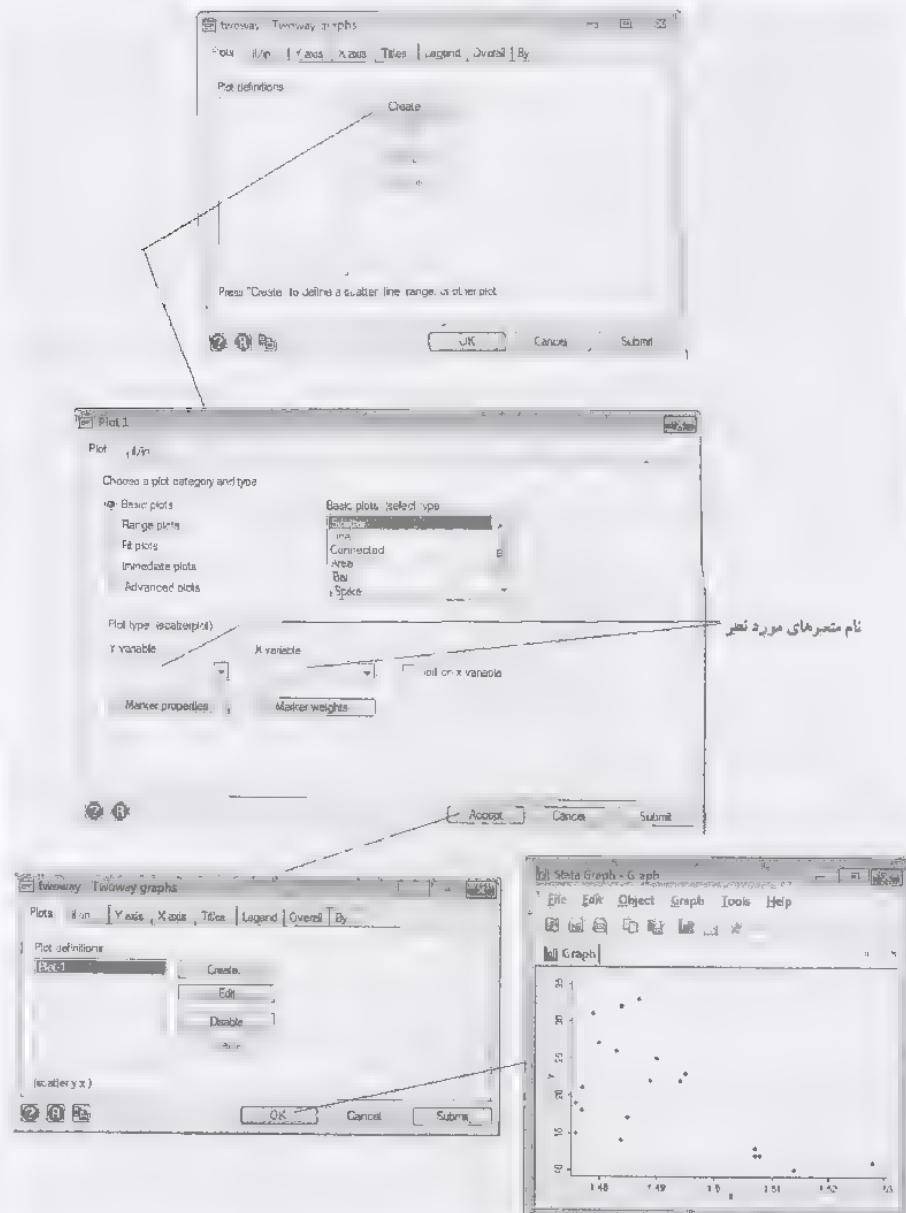
تا هنگامی که هر یک از این فرمان‌ها را اجرا نکنید، stata متغیر زمان را نمی‌شناسد.

نمودارها

برای رسم نمودارها از منوی Graphics استفاده می‌شود که گزینه‌های مختلفی برای ترسیم نمودار به شرح زیر دارد:



اولین گزینه تحت عنوان twoway graph(scater, line, etc) است که پیش از بقیه مورد استفاده می‌باشد. با انتخاب این گزینه، پنجره زیر باز می‌شود:



و یا می‌توان از فرمان‌های کوتاه مانند `scatter y x` در سطر فرمان استفاده نمود.

همچنین می‌توان نمودار `y` در مقابل `x` را با فرمان زیر ترسیم نمود.

`twoway (scatter y x)`

برای رسم نمودارهای سری زمانی از فرمان زیر استفاده می‌شود:

`twoway (line y x t)`

line نوع نمودار، `x` و `y` نام متغیرها، و `t` مقادیر روی محور `x` است که می‌تواند زمان یا هر چیز دیگری باشد.

علاوه بر این می‌توان از فرمان زیر برای رسم نمودارهای معمولی مانند سری زمانی استفاده نمود:

`tsline y x`

سایر فرمان‌ها

`l.y` یا `l1.y` وقفه مرتبه یک (مقدار `y` در زمان $t-1$)

`l2.y` وقفه مرتبه دو (مقدار `y` در زمان $t-2$)

`f.y` یا `f1.y` مقدار `y` در زمان $t+1$

`f2.y` مقدار `y` در زمان $t+2$

`d.y` یا `d1.y` تفاضل مرتبه اول ($y_t - y_{t-1}$)

`d2.y` تفاضل مرتبه اول ($y_t - y_{t-1}$) - ($y_{t-1} - y_{t-2}$)

`ds.y` تفاضل‌های فصلی ($y_t - y_{t-s}$)

`d2s.y` ($y_t - y_{t-2s}$)

$s=4$ برای فصل (سه ماهه) و $s=12$ برای ماهانه

همچنین برای محاسبه مقادیر تأخیری (وقفه) می‌توان از فرمان زیر استفاده نمود:

`gen y1=y[_n-1]`

افزودن دامنه

گاهی اوقات برای اضافه کردن داده‌ها و یا برای پیش‌بینی برون‌نمونه‌ای، لازم است که دامنه مورد نظر را گسترش دهیم. بدین منظور می‌توان فرمان زیر را اجرا نمود:

`tsappend, add(10)`

فرمان فوق، دامنه مورد نظر را ۱۰ افزایش می‌دهد که می‌تواند سال، ماه و غیره باشد. مثلاً دامنه را که قبلاً تا سال ۱۳۸۰ بوده تا سال

۱۳۹۰ اضافه می‌کند. علاوه بر این می‌توان از فرمان زیر استفاده نمود.

```
tsappend, last (1380) tsfmt(ty)
```

برای داده‌های فصلی، آخرین فصل (1380q4) را مشخص کرده و به جای ty از tq استفاده می‌کنیم. همین فرمان را برای داده‌های ماهانه نیز می‌توان استفاده نمود که در این حالت آخرین زمان مثلاً 1380m12 را معلوم کرده و به جای ty از tm استفاده می‌کنیم.

سایر علائم

== مساوی

!= مساوی نیست با -

> بزرگتر از

< کوچکتر از

>= بزرگتر یا مساوی

<= کوچکتر یا مساوی

& و

| یا

نحافظ نکردن برخی از مشاهدات

اگر بخواهیم در تخمین معادلات و یا در سایر محاسبات، شرطی را قائل شویم می‌توان آن را با if لحاظ نمود. به عنوان مثال می‌خواهیم آن بخش از مشاهدات که y برابر صفر است، در نظر گرفته نشوند. بدین منظور از فرمان زیر استفاده می‌کنیم:

```
Drop if y==0
```

این فرمان موجب حذف آن بخش از مشاهدات می‌شود که $y=0$ است. همچنین می‌توان به جای صفر هر عدد دیگری را نیز در نظر گرفت. به جای مساوی می‌توان از کوچکتر و بزرگتر نیز استفاده نمود.

حذف یک متغیر

متغیر y را می‌توان با فرمان زیر حذف نمود:

```
drop y
```

همچنین اجرای فرمان زیر، همه متغیرهای یک فایل مجز متغیرهای x، y و z را حذف می‌کند:

```
keep x y z
```

نشان گذاری متغیرها

متغیرها که با حروف لاتین نشان داده می‌شوند نیاز به توصیف بیشتری دارند. در این خصوص می‌توان با استفاده از فرمان زیر، یک برچسب را برای متغیر مورد نظر انتخاب نمود. به عنوان مثال می‌خواهیم نشان دهیم که y بیانگر رشد GDP است:

label variable y "growth of GDP"

با اجرای این فرمان، عبارت growth of GDP مقابل متغیر y ظاهر می‌شود.

رگرسیون ساده

۲-۱ مقدمه

در تحلیل رگرسیون ساده، تبیین رابطه بین دو متغیر بررسی می‌شود. برخلاف همبستگی، در اینجا میزان تأثیر یک متغیر بر دیگری اندازه‌گیری می‌شود. به عنوان مثال رابطه بین تورم و رشد نقدینگی را می‌توان از طریق محاسبه ضریب همبستگی و یا از طریق رگرسیون بررسی نمود. ضریب همبستگی به بررسی وجود یا عدم وجود رابطه خطی می‌پردازد، اما در تحلیل رگرسیون، یک متغیر (مانند تورم) را تابعی از متغیر دیگر (مانند رشد نقدینگی) در نظر می‌گیریم. بررسی این موارد نیاز به روش‌هایی دارد که اصول آنها در این فصل بررسی می‌شود. بدین منظور در این فصل، ابتدا به مبانی نظری رگرسیون و سپس به روش‌های کاربردی آن خواهیم پرداخت. مبنای تحلیل رگرسیون عمدتاً بر توزیع‌های چند متغیره و توزیع‌های شرطی است که معادله رگرسیون را به صورت میانگین شرطی ارائه می‌کند. بدین منظور بحث را با امید ریاضی شرطی شروع می‌کنیم.

۲-۲ امید ریاضی شرطی و رگرسیون

در تحلیل رگرسیون معمولاً یکی از متغیرها را وابسته و دیگری را مستقل فرض می‌کنیم. در ابتدا باید توجه داشت که در تابع $Y = f(X)$ به ازای X ، یک مقدار معین برای Y وجود دارد. به عبارت دیگر به ازای $X = a$ همواره $Y = f(a)$ خواهد بود. اما در تحلیل رگرسیون به ازای $X = a$ ، الزاماً همواره $Y = f(a)$ به دست نمی‌آید. یعنی اگر X را در سطح a کنترل کنیم،

الزاماً مقدار $Y = f(a)$ به دست نمی آید، زیرا عوامل دیگری (به جز X) وجود دارند که بر Y اثر می گذارند. در واقع این بحث بیانگر تفاوت شرایط مطمئن با شرایط نامطمئن می باشد. به همین دلیل، وقتی به ازای هر X چندین Y وجود دارد، بایستی از متوسط های Y استفاده نمود که معروف به میانگین های شرطی یا امید ریاضی شرطی می باشد. بنابراین ابتدا لازم است مفهوم امید ریاضی شرطی را بررسی کنیم.

بدین منظور، بحث را با تابع احتمال مشترک پی گیری می کنیم. فرض کنید تابع احتمال (چگالی) مشترک X و Y به صورت زیر باشد:

$$f(x, y) = \frac{y}{3}(x + 2y) \quad 0 < x < 1, \quad 0 < y < 1$$

توزیع های حاشیه ای یا توزیع تکی هر یک از متغیرها و همچنین توزیع شرطی Y عبارت است از:

$$f(x) = \int_0^1 f(x, y) dy = \int_0^1 \frac{y}{3}(x + 2y) dy = \frac{y}{3}(1 + x)$$

$$f(y) = \int_0^1 f(x, y) dx = \int_0^1 \frac{y}{3}(x + 2y) dx = \frac{1}{3}(1 + 4y)$$


$$f(y|x) = \frac{f(x, y)}{f(x)} = \frac{\frac{y}{3}(x + 2y)}{\frac{y}{3}(1 + x)} = \frac{x + 2y}{x + 1}$$

$f(x)$ و $f(y)$ به ترتیب تابع احتمال X و Y بوده و $f(y|x)$ نیز تابع احتمال شرطی Y می باشد. با استفاده از تابع احتمال شرطی می توان رابطه بین دو متغیر X و Y را بررسی نمود. اگر شرط $f(y|x) = f(y)$ برقرار باشد، در این صورت این دو متغیر، مستقل اند و هیچ رابطه ای با هم ندارند. اما در غیر این صورت متغیرهای مذکور، مستقل نیستند. در مثال فوق، چون $f(y|x) \neq f(y)$ است لذا X و Y مستقل نیستند.

اما سؤال این است که چگونه رابطه بین X و Y را به صورت کمی بررسی کنیم. یکی از راههای مناسب این است که امید ریاضی شرطی Y را حساب کنیم. بدیهی است که اگر Y مستقل از X باشد در این صورت $f(y|x) = f(y)$ و $E(Y|X) = E(Y)$ می باشد و در نتیجه امید ریاضی شرطی Y تابعی از X نخواهد بود. در مثال فوق امید ریاضی شرطی Y عبارت است از:

$$E(Y|X) = \int y f(y|x) dy = \int y \frac{x+2y}{x+1} dy = \frac{3x+4}{2(x+1)}$$

بنابراین همان‌طور که انتظار می‌رفت، امید ریاضی شرطی Y تابعی از X است.



نمودار ۲-۱: امید ریاضی شرطی

پس به‌طور کلی اگر دو متغیر X و Y مستقل نباشند، امید ریاضی شرطی Y تابعی از X خواهد بود:

$$E(Y|X) = g(X) \quad (2-1)$$

معادله (۲-۱) موسوم به معادله رگرسیون Y روی X می‌باشد. این تابع فقط رابطه بین میانگین‌های شرطی Y با متغیر X بوده که ممکن است خطی یا غیرخطی باشد. اگر خطی باشد، می‌توان آن را در حالت کلی به‌صورت زیر نوشت:

$$E(YX) = \alpha + \beta X \quad (2-2)$$

در کاربردهای تجربی، معمولاً از معادله خطی استفاده می‌شود و یا اگر معادله‌ای غیرخطی باشد، می‌توان آن را با تقریب، تبدیل به خطی نمود.

رگرسیون نرمال

اگر تابع احتمال مشترک X و Y ، نرمال باشد، آنگاه امید ریاضی شرطی Y تابع خطی از X خواهد بود. تابع احتمال مشترک نرمال عبارت است از:

$$f(x, y) = \frac{1}{\sqrt{2\pi}\sigma_x\sigma_y\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x-\mu_x}{\sigma_x}\right)^2 - 2\rho\left(\frac{x-\mu_x}{\sigma_x}\right)\left(\frac{y-\mu_y}{\sigma_y}\right) + \left(\frac{y-\mu_y}{\sigma_y}\right)^2\right]}$$

تابع احتمال شرطی Y نیز عبارت است از:

$$f(y|x) = \frac{f(x, y)}{f(x)} = \frac{1}{\sqrt{2\pi}\sigma_y\sqrt{1-\rho^2}} e^{-\frac{\left[y - \left(\mu_y + \rho\frac{\sigma_y}{\sigma_x}(x-\mu_x)\right)\right]^2}{2\sigma_y^2(1-\rho^2)}}$$

X و Y مستقل نیستند، زیرا $f(x, y) \neq f(x)f(y)$ و $f(y|x) \neq f(y)$ می باشد.

در اینجا ρ ضریبی است که وابستگی X و Y را بیان می کند. اگر $\rho = 0$ باشد، آنگاه $f(x, y) = f(x)f(y)$ و $f(y|x) = f(y)$ خواهد شد که بیانگر استقلال X و Y است. امید

ریاضی شرطی Y عبارت است از:

$$\begin{aligned} E(Y|X) &= \int_{-\infty}^{+\infty} y f(y|x) dy = \mu_y + \rho \frac{\sigma_y}{\sigma_x} (X - \mu_x) \\ &= (\mu_y - \rho \frac{\sigma_y}{\sigma_x} \mu_x) + \rho \frac{\sigma_y}{\sigma_x} X = \alpha + \beta X \\ \alpha &= \mu_y - \rho \frac{\sigma_y}{\sigma_x} \mu_x, \quad \beta = \rho \frac{\sigma_y}{\sigma_x} \end{aligned}$$

همچنین واریانس شرطی Y برابر است با:

$$\text{var}(Y|X) = \sigma_{y|x}^2 = \int_{-\infty}^{+\infty} (y - E(y|x))^2 f(y|x) dy = \sigma_y^2 (1 - \rho^2)$$


مثال ۱: اگر $\mu_x = 5$ ، $\mu_y = 4$ ، $\sigma_x = 4$ ، $\sigma_y = 2$ و $\rho = 0.8$ باشد، معادله رگرسیون را رسم کنید.

$$\alpha = 4 - (0.8 \times \frac{2}{4})5 = 2, \quad \beta = 0.8 \times \frac{2}{4} = 0.4$$

$$E(Y|X) = 2 + 0.4X$$

واریانس شرطی Y عبارت است از:

$$\sigma_{y|x}^2 = 2^2 (1 - 0.8^2) = 1.44$$



نمودار ۲-۲: امید ریاضی شرطی خطی در توزیع نرمال

به هر حال طبق رابطه (۲-۱) امید ریاضی شرطی Y تابعی از X است. اگر توزیع مشترک X و Y نرمال باشد، آنگاه امید ریاضی شرطی Y تابع خطی از X خواهد بود. اگر امید ریاضی شرطی Y غیر خطی باشد می توان آن را با استفاده از بسط توابع با تقریب مرتبه اول، خطی نمود.^۱ به طور کلی، امید ریاضی شرطی Y را به صورت $E(Y|X) = \alpha + \beta X$ در نظر می گیریم. اما بدیهی است که مقادیر واقعی Y با $E(Y|X)$ تفاوت دارند و در این خصوص مرتکب خطا می شویم. به همین دلیل لازم است که این خطاها را وارد این معادله نماییم.

۲-۳ جمله خطا و معادله رگرسیون

بنا بر آنچه گفته شد معادله (۲-۲) فقط آن بخش از تغییرات Y را توضیح می دهد که متأثر از متغیر X می باشد. حال تأثیر بقیه عوامل را که تصادفی و غیر قابل کنترل هستند در این معادله وارد می کنیم. اثر سایر عوامل را با u نشان می دهیم. بنابراین برای هر مقدار از Y می توان رابطه زیر را نوشت:

$$Y = E(Y|X) + u \Rightarrow Y = \alpha + \beta X + u \quad (2-3)$$

^۱تقریب خطی تابع $g(x)$ در $x = a$ عبارت است از:

$$g(x) \cong g(a) + g'(a)(x-a)$$

که در اینجا $\alpha = g(a) - g'(a)a$ و $\beta = g'(a)$ خواهد بود.

بدین ترتیب طبق الگوی (۲-۳) تغییرات Y به دو دسته تقسیم می‌شود: یکی تغییراتی که متأثر از X است و آن را قابل کنترل و غیرتصادفی می‌دانیم که اصطلاحاً به آن «جزء معین یا غیرتصادفی» می‌گویند و دیگری تغییراتی که ناشی از عوامل تصادفی و غیرقابل کنترل است که اصطلاحاً به آن «جزء تصادفی» یا «جزء اختلال» یا «جمله خطا» می‌گویند.

حال معادله (۲-۳) را برای مشاهده i ام می‌نویسیم:

$$Y_i = \alpha + \beta X_i + u_i \quad (2-4)$$

از آنجا که u_i تحت تأثیر عوامل متعددی قرار دارد و تصادفی می‌باشد، لذا u_i یک متغیر تصادفی است. از طرف دیگر هر متغیر تصادفی خصوصیتی دارد که توسط توزیع آن متغیر و فروض مربوط به آن بیان می‌شود. در ادامه بحث، به بررسی فروض مربوط به جمله اختلال می‌پردازیم.

۲-۴ فروض معادله رگرسیون

فروض معادله رگرسیون یا فروض کلاسیک، خصوصیات جزء تصادفی مدل رگرسیون را تبیین می‌کنند. این فروض عبارتند از:

- | | |
|---|---|
| ۱) $E(u_i X) = 0$ | فرض میانگین صفر |
| ۲) $\text{var}(u_i X) = E(u_i^2 X) = \sigma^2 < \infty$ | فرض واریانس همسانی |
| ۳) $\text{cov}(u_k, u_j) = E(u_k u_j) = 0 \quad k \neq j$ | فرض عدم خودهمبستگی |
| ۴) $\text{cov}(u_i, X_i) = 0$ | فرض استقلال جزء تصادفی (u_i) از جزء غیرتصادفی (X_i) |
| ۵) $u_i \sim N(0, \sigma^2)$ | فرض نرمال بودن |

مفاهیم مربوط به این فروض در مثال زیر ارائه شده است:

فرض کنید که نمره امتحان دانشجویی (Y) تابعی از میزان ساعات مطالعه وی (X) در روز قبل از امتحان باشد. بدیهی است که عوامل بی‌شمار دیگری نیز دخیل هستند که آنها را با u نشان می‌دهیم، از قبیل این که دوستش به او تلفن بزند و یک ساعت وقت او را بگیرد، مهمان برای آنها بیاید، برق قطع شود، کتابش گم شود و هزاران مسئله دیگر. اینها عوامل غیرقابل کنترل هستند. همچنین فرض کنید که رابطه $E(Y|X) = 4 + 0.8X$ برقرار باشد. این رابطه بیانگر یک «رابطه

انتظاری است. مثلاً انتظار بر این است که اگر ۱۰ ساعت مطالعه کند ($X=10$)، نمره وی ۱۲ خواهد شد. اما به دلیل وجود عوامل تصادفی ممکن است عملاً به نمره ۱۲ دست پیدا نکند و به نتیجه دیگری برسد. همان طور که گفته شد X متغیر قابل کنترل ولی u متغیر تصادفی است:

$$Y_i = E(Y|X) + u_i = (4 + 0.8X_i) + u_i \Rightarrow u_i = Y_i - (4 + 0.8X_i)$$

حال فرض کنید مشاهده k ام بدین صورت بوده که او ۱۰ ساعت مطالعه کند و نمره امتحانش برابر با ۱۲/۵ شده باشد. در این شرایط مشاهده k ام به صورت $(X_k=10, Y_k=12/5)$ می باشد و آنگاه u_k برابر است با:

$$u_k = Y_k - (4 + 0.8X_k) = 12/5 - (4 + 0.8 \times 10) = 12/5 - 12 = -0.8$$


حال تصور کنید که این آزمایش را بتوان تکرار کرده و به روز قبل از امتحان برگردیم و مشاهده k ام را یک بار دیگر اندازه گیری کنیم. در این حالت قسمت قابل کنترل همچنان مانند قبل است، یعنی $X_k=10$ و $E(Y|X_k=10) = 4 + 0.8 \times 10 = 12$ می باشد. اما نمره او به دلیل وجود عوامل تصادفی برابر با ۱۲/۵ نخواهد شد و به عنوان مثال برابر با ۱۱ شود:

$$u_k = Y_k - (4 + 0.8X_k) = 11 - (4 + 0.8 \times 10) = 11 - 12 = -1$$


اگر آزمایش را دوباره تکرار کنیم و به روز قبل از امتحان برگردیم و X_k را در سطح ۱۰ کنترل کنیم، این بار نمره او ممکن است به عنوان مثال برابر با ۱۳/۲۵ شود:

$$u_k = Y_k - (4 + 0.8X_k) = 13/25 - (4 + 0.8 \times 10) = 13/25 - 12 = -1/25$$

اگر این آزمایش را مجدداً تکرار کنیم و جزء غیر تصادفی را در سطح $X_k=10$ کنترل کنیم، به Y_k های متفاوتی می رسیم که ناشی از عوامل تصادفی است. در این صورت جزء غیر تصادفی مدل همواره برابر با $E(Y|X_k=10) = 4 + 0.8 \times 10 = 12$ خواهد بود. اما جزء تصادفی مدل چون قابل کنترل نمی باشد دارای مقادیر غیر قابل پیش بینی خواهد بود:




این بحث را روی نمودار نیز می‌توان نشان داد:



نمودار ۲-۳: خطاهای تصادفی و معادله رگرسیون

اگر این آزمایش را به تعداد زیاد تکرار کنیم آنگاه مشاهده خواهد شد که u_k در اطراف عدد ۱۲ (در حالت کلی در اطراف $\alpha + \beta x_k$) نوسان می‌کند. در صورت تصادفی بودن u_k ، میانگین آن باید صفر شود که یکی از فروض اساسی این مدل است.

اما مفهوم یکسان بودن واریانس u_i این است که وقتی $x_k = 10$ است، پراکندگی (واریانس) u_k برابر با σ^2 می‌باشد. حال اگر آزمایش‌های تکراری را در سطح $x_j = 15$ نیز انجام دهیم در این صورت y_j ‌های مشاهده شده، ناشی از $x_j = 15$ و u_j ‌ها خواهد بود. در اینجا نیز چون $E(Y|x_j = 15) = 4 + 0.8 \times 15 = 16$ است لذا u_j ‌ها در اطراف عدد ۱۶ نوسان می‌کند که $E(u_j) = 0$ و واریانس آن $E(u_j) = \sigma^2$ خواهد بود. این بدان معنا است که واریانس u_i مستقل از x_i است که موسوم به فرض «واریانس همسانی» می‌باشد. به عبارت دقیق‌تر u_i دارای توزیع نرمال با میانگین ۰ و واریانس σ^2 است که این توزیع، مستقل از مقدار x_i می‌باشد. این مفهوم در نمودار ۲-۴ نشان داده شده است:



نمودار ۲-۴

فرض عدم رابطه بین u_i ها بدین معنی است که u_j و u_k مستقل اند:

$$\text{cov}(u_k, u_j) = E[(u_k - Eu_k)(u_j - Eu_j)] = E(u_k u_j) = 0 \quad k \neq j$$

این فرض موسوم به عدم «خودهمبستگی» است که در فصل چهارم بحث خواهد شد. مفهوم این فرض آن است که خطاهای تصادفی، مستقل هستند. به عبارت دیگر خطاهای امروز مستقل از خطاهای دیروز است. یا خطاها در یک آزمایش (مشاهده) مستقل از خطاها در آزمایش دیگر است. این بدان معنا است که خطاها باید واقعاً تصادفی باشند و هیچ نظم و ترتیبی در آنها مشاهده نشود. اگر خطاها نظام مند (سیستماتیک) باشند آنگاه دچار همبستگی خواهند شد.

فرض غیرتصادفی بودن X بدین معنی است که در آزمایش‌های تکراری، X_k ثابت است و لذا برای آن، $E(X_k) = X_k$ و $\text{var}(X_k) = 0$ خواهد بود.^۱ بنابراین بدین نتیجه خواهیم رسید که X_k و u_k مستقل اند. به عبارت دیگر جزء تصادفی و جزء غیرتصادفی مستقل هستند. حتی اگر X نیز تصادفی باشد، فرض بر این است که فرایندی که داده‌های X را ایجاد می‌کند و فرایندی که u را ایجاد می‌کند، مستقل اند.

$$\text{cov}(u_k, X_k) = E[(u_k - Eu_k)(X_k - EX_k)] = E[u_k(X_k - EX_k)] = (Eu_k)E(X_k - EX_k) = 0$$

بر اساس فروض فوق، می‌توان خصوصیات Y_i را نیز بررسی نمود. از آنجا که Y_i تابعی از u_i

۱- این نکته با این بحث که X پراکندگی ندارد، اشتباه نشود. در اینجا منظور این است که X_k در آزمایش‌های تکراری، ثابت است و لذا $\text{var}(X_k) = 0$ می‌باشد، اما واریانس X که با $\text{var}(X)$ نشان داده می‌شود به صورت زیر می‌باشد:

$$\sigma_x^2 = \text{var}(X) = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

است، لذا Y_i نیز یک متغیر تصادفی است. علاوه بر این، چون u_i نرمال است لذا Y_i که تابع خطی از u_i است، نیز نرمال خواهد بود:

$$۱) Y_i = \alpha + \beta X_i + u_i$$

$$۲) E(Y|X_i) = \alpha + \beta X_i, \quad E(u_i|X_i) = 0$$

$$۳) \text{var}(Y|X_i) = \sigma^2_{y|x_i} = \text{var}(u_i|X_i) = \sigma^2$$

$$۴) Y_i \sim N(\alpha + \beta X_i, \sigma^2)$$

۲-۵ تحلیل رگرسیون تجربی

آنچه تا اینجا بررسی شد مربوط به مبانی نظری تحلیل رگرسیون می‌باشد. اما در مباحث تجربی، صرفاً با مجموعه‌ای از مشاهدات مواجه‌ایم که بر اساس نمونه‌گیری به‌دست آمده است. به‌عنوان مثال در تحلیل رابطه دو متغیر X و Y فقط مجموعه‌ای از داده‌های جفت‌شده را به‌صورت $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ در اختیار داریم.

در تحلیل رگرسیون نظری بدین نتیجه رسیدیم که معادله رگرسیون نظری به‌صورت $E(Y|X_i) = \alpha + \beta X_i$ است. اولاً ممکن است این معادله، خطی نباشد ولی برای سادگی آن را خطی فرض کرده‌ایم که البته در صورت برقراری فرض نرمال بودن u_i ، به تبع آن Y_i نیز توزیع نرمال خواهد داشت و فرض خطی بودن می‌تواند واقعی باشد. ثانیاً معادله رگرسیون $E(Y|X_i) = \alpha + \beta X_i$ بیانگر مقدار انتظاری Y_i است نه مقدار دقیق آن. در واقع برآورد ما از Y_i طبق $\alpha + \beta X_i$ صورت می‌گیرد که برای ما قابل کنترل است. در حالی که مقدار واقعی Y_i برابر با $Y_i = \alpha + \beta X_i + u_i$ است. ثالثاً معادله رگرسیون $E(Y|X_i) = \alpha + \beta X_i$ را نمی‌دانیم، زیرا α و β مجهول هستند. بنابراین مشکل اصلی این است که چگونه α و β را تعیین کنیم. فرض کنید که به هر طریقی α و β را برآورد کرده و آن را با $\hat{\alpha}$ و $\hat{\beta}$ نشان دهیم. در این صورت برآورد ما از Y_i برابر با $\hat{\alpha} + \hat{\beta}X_i$ خواهد بود که متفاوت از $\alpha + \beta X_i$ است. بنابراین اگر برآوردی را که طبق معادله $\hat{\alpha} + \hat{\beta}X_i$ به‌دست می‌آوریم با \hat{Y}_i نشان دهیم آنگاه در رسیدن به Y_i دچار خطایی به اندازه $Y_i - \hat{Y}_i$ خواهیم شد که آن را با e_i نشان می‌دهیم. لذا در تحلیل رگرسیون تجربی، رابطه $\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$ و $Y_i = (\hat{\alpha} + \hat{\beta}X_i) + e_i$ را داریم. در واقع به‌جای $\alpha + \beta X_i$ از $\hat{\alpha} + \hat{\beta}X_i$ و

به جای u_i از e_i استفاده می‌کنیم. به‌طور خلاصه، تحلیل رگرسیون نظری و تجربی در جدول زیر نشان داده شده است:

مقدار واقعی	مقدار تخمینی		مقدار خطا	
	رگرسیون نظری	رگرسیون تجربی	خطای واقعی	خطای تخمینی
Y_i	$E(Y X_i) = \alpha + \beta X_i$	$\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$	$u_i = Y_i - E(Y X_i)$ $= Y_i - (\alpha + \beta X_i)$	$\hat{u}_i = e_i = Y_i - \hat{Y}_i$ $= Y_i - (\hat{\alpha} + \hat{\beta} X_i)$

به‌مرحال چون α و β را نمی‌دانیم لذا امکان دسترسی به معادله $E(Y|X_i) = \alpha + \beta X_i$ وجود ندارد و به ناچار باید از تخمین α و β استفاده کنیم تا بدین طریق معادله $\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$ را جایگزین معادله $E(Y|X_i) = \alpha + \beta X_i$ کنیم. بدین ترتیب بحث بعدی ما راجع به برآورد ضرایب α و β خواهد بود.

۲-۶ تخمین معادله رگرسیون


همان‌طور که در بخش قبلی اشاره شد، در مطالعات کاربردی صرفاً داده‌های نمونه را داریم که شامل $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ می‌باشد. حال با استفاده از این داده‌ها، ضرایب α و β را برآورد می‌کنیم. فرض کنید که $\hat{\alpha}$ و $\hat{\beta}$ تخمین α و β باشند. در این صورت روابط زیر را داریم:

$$\text{مقدار واقعی} = Y_i$$

$$\text{مقدار تخمینی} = \hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i \quad (2-5)$$

$$\text{مقدار خطا} = \hat{u}_i = e_i = Y_i - \hat{Y}_i = Y_i - (\hat{\alpha} + \hat{\beta} X_i) \quad (2-6)$$

یکی از معیارهای مناسب برای تعیین $\hat{\alpha}$ و $\hat{\beta}$ این است که خطا را حداقل کنیم. بدین منظور اگر مشاهدات X و Y را روی نمودار ترسیم کنیم، نقاط پراکنده‌ای به‌دست می‌آید که باید خط رگرسیون به‌گونه‌ای از بین این نقاط بگذرد که کمترین خطا را به‌وجود آورد. فرض کنید که ۵ مشاهده برای X و Y داریم که در نمودار ۲-۵ ترسیم شده است.



نمودار ۲-۵: خط رگرسیون تجربی

از آنجا که خطاهای مثبت و منفی همدیگر را خنثی می‌کنند، لذا مجموع خطاهای یعنی $\sum e_i$ برابر صفر است. بدین منظور از مجموع مجذور خطاها استفاده می‌شود:

$$\sum_{i=1}^n e_i^2 = e_1^2 + e_2^2 + \dots + e_n^2 \quad (2-7)$$

در تخمین $\hat{\alpha}$ و $\hat{\beta}$ بایستی مجموع مربعات خطا حداقل شود. این روش، معروف به روش حداقل مربعات معمولی (OLS)^۱ است. با جایگذاری از (۲-۶) در (۲-۷) خواهیم داشت:

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}X_i)^2 \quad (2-8)$$

عبارت فوق وقتی حداقل می‌شود که خط رگرسیون به گونه‌ای ترسیم شود که در مجموع، کمترین خطا را ایجاد کند. بدیهی است که موقعیت خط رگرسیون بستگی به عرض از مبدأ آن ($\hat{\alpha}$) و شیب آن ($\hat{\beta}$) دارد. لذا $\hat{\alpha}$ و $\hat{\beta}$ را به گونه‌ای تعیین می‌کنیم که مجموع مجذور خطا را حداقل نماید. این کار را می‌توان با مشتق‌گیری نسبت به $\hat{\alpha}$ و $\hat{\beta}$ انجام داد:

^۱Ordinary Least Squares

$$\frac{\partial \sum e_i^2}{\partial \hat{\alpha}} = -2 \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} X_i) = 0$$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}} = -2 \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} X_i)(-X_i) = 0$$

با ساده نمودن این معادلات، خواهیم داشت:

$$\sum (Y_i - \hat{\alpha} - \hat{\beta} X_i) = 0 \quad \text{یا} \quad \sum e_i = 0 \quad (2-9)$$

$$\sum (Y_i - \hat{\alpha} - \hat{\beta} X_i) X_i = 0 \quad \text{یا} \quad \sum e_i X_i = 0$$

معادلات (2-9) معروف به معادلات نرمال هستند. با حل معادله اول خواهیم داشت:

$$\sum Y_i - n\hat{\alpha} - \hat{\beta} \sum X_i = 0 \Rightarrow \hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$

حال به جای $\hat{\alpha}$ در معادله دوم قرار داده و $\hat{\beta}$ را به دست می آوریم:^۱

$$\sum [Y_i - (\bar{Y} - \hat{\beta} \bar{X}) - \hat{\beta} X_i] X_i = 0 \Rightarrow \sum [(Y_i - \bar{Y}) - \hat{\beta} (X_i - \bar{X})] X_i = 0$$

$$\Rightarrow \sum [(Y_i - \bar{Y}) X_i - \hat{\beta} (X_i - \bar{X}) X_i] = 0$$

با حل معادله فوق برای $\hat{\beta}$ خواهیم داشت:

$$\hat{\beta} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{\sum X_i^2 - n \bar{X}^2} \quad (2-10)$$

از اینجا به بعد، حروف بزرگ را برای مقادیر معمولی متغیرها و حروف کوچک را برای انحراف از میانگین، استفاده می کنیم. لذا $X_i - \bar{X} = x_i$ و $Y_i - \bar{Y} = y_i$ می باشد. بر این اساس، $\hat{\beta}$ برابر است با:

$$\hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2}$$

که $\sum x_i y_i = \sum (X_i - \bar{X})(Y_i - \bar{Y}) = \sum X_i Y_i - n \bar{X} \bar{Y}$ و $\sum x_i^2 = \sum (X_i - \bar{X})^2 = \sum X_i^2 - n \bar{X}^2$ است.

^۱ توجه شود که روابط زیر برقرار است:

$$\sum (X_i - \bar{X}) X_i = \sum (X_i - \bar{X})^2$$

$$\sum (Y_i - \bar{Y}) X_i = \sum (X_i - \bar{X})(Y_i - \bar{Y})$$

مثال ۲-۲: مشاهدات X شامل ۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵، ۱۶، ۱۷، ۱۸، ۱۹، ۲۰، ۲۱، ۲۲ و ۲۳ شامل Y شامل ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵، ۱۶، ۱۷، ۱۸، ۱۹، ۲۰، ۲۱، ۲۲ و ۲۳ می‌باشد. معادله رگرسیون Y روی X را برآورد کنید.

X_i	Y_i	X_i^2	Y_i^2	$X_i Y_i$
۱	۵	۱	۲۵	۵
۲	۶	۴	۳۶	۱۲
۳	۷	۹	۴۹	۲۱
۴	۸	۱۶	۶۴	۳۲
۵	۹	۲۵	۸۱	۴۵
۶	۱۰	۳۶	۱۰۰	۶۰
۷	۱۱	۴۹	۱۲۱	۷۷
۸	۱۲	۶۴	۱۴۴	۹۶
۹	۱۳	۸۱	۱۶۹	۱۱۷
۱۰	۱۴	۱۰۰	۱۹۶	۱۴۰
۱۱	۱۵	۱۲۱	۲۲۵	۱۶۵
۱۲	۱۶	۱۴۴	۲۵۶	۱۹۲
۱۳	۱۷	۱۶۹	۲۸۹	۲۲۱
۱۴	۱۸	۱۹۶	۳۲۴	۲۵۲
۱۵	۱۹	۲۲۵	۳۶۱	۲۸۵
۱۶	۲۰	۲۵۶	۴۰۰	۳۲۰
۱۷	۲۱	۲۸۹	۴۴۱	۳۵۹
۱۸	۲۲	۳۲۴	۴۸۴	۳۹۶
۱۹	۲۳	۳۶۱	۵۲۹	۴۳۷
۲۰	۲۴	۴۰۰	۵۷۶	۴۸۰
۲۱	۲۵	۴۴۱	۶۲۵	۵۲۵
۲۲	۲۶	۴۸۴	۶۷۶	۵۷۲
۲۳	۲۷	۵۲۹	۷۲۹	۶۲۱
۱۲۸	۲۴۲	۹۷۸	۳۳۳۸	۱۷۶۸

$$\bar{X} = \frac{128}{20} = 6.4, \quad \bar{Y} = \frac{242}{20} = 12.1$$

$$\sum x_i^2 = 978 - 20(6.4)^2 = 158/8$$

$$\sum y_i^2 = 3338 - 20(12.1)^2 = 40.9/8$$

$$\sum x_i y_i = 1768 - 20(6.4)(12.1) = 219/2$$

$$\hat{\beta} = \frac{219/2}{158/8} = 1/38, \quad \hat{\alpha} = 12.1 - 1/38 \times 6.4 = 3/266$$

تخمین معادله رگرسیون عبارت است از:

$$\hat{Y}_i = 3/266 + 1/38 X_i$$

۲-۷ خواص تخمین‌زننده‌های OLS

هر تخمین‌زننده‌ای بایستی برخی خواص مطلوب را داشته باشد. در این راستا، تخمین‌زننده‌های OLS را اصطلاحاً بهترین تخمین خطی بدون تورش^۱ می‌گویند. در اینجا هر یک از این خواص را بررسی می‌کنیم.

^۱Best Linear Unbiased Estimation (BLUE)

۲-۷-۱ تخمین زنده خطی

$\hat{\beta}$ را می‌توان به صورت زیر نوشت^۱:

$$\begin{aligned}\hat{\beta} &= \frac{\sum x_i y_i}{\sum x_i^2} = \frac{\sum x_i Y_i}{\sum x_i^2} = \sum w_i Y_i \\ &= \sum w_i (\alpha + \beta X_i + u_i) = \beta + \sum w_i u_i \quad ; \quad w_i = \frac{x_i}{\sum x_i^2}\end{aligned}\quad (2-11)$$

در اینجا از روابط $\sum w_i X_i = 1$ و $\sum w_i = 0$ استفاده شده است. بدین ترتیب ملاحظه می‌شود که $\hat{\beta}$ تابع خطی از متغیرهای تصادفی نرمال است و لذا $\hat{\beta}$ نیز یک متغیر تصادفی نرمال می‌باشد.

۲-۷-۲ بدون تورش بودن

با توجه به فرض غیر تصادفی بودن X_i و استقلال آن از u_i ، خواهیم داشت:

$$E(\hat{\beta}) = E(\beta + \sum w_i u_i) = \beta + \sum w_i E(u_i) = \beta \quad (2-12)$$

زیرا $E(u_i) = 0$ است.

۲-۷-۳ سازگاری

سازگاری یک تخمین زنده بدون تورش بیانگر آن است که با افزایش حجم نمونه، واریانس آن به سمت صفر میل کند. بدین منظور واریانس $\hat{\beta}$ را حساب می‌کنیم. با استفاده از (۲-۱۱) داریم:

$$\begin{aligned}\text{var}(\hat{\beta}) &= E(\hat{\beta} - \beta)^2 = E(\sum w_i u_i)^2 = \sum_{i=1}^n E(w_i u_i)^2 + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n E(w_i w_j u_i u_j) \\ &= \sum_{i=1}^n w_i^2 E(u_i^2) + \sum_{\substack{i=1 \\ i \neq j}}^n \sum_{j=1}^n w_i w_j E(u_i u_j) = \sum_{i=1}^n w_i^2 \sigma^2 = \sigma^2 \sum_{i=1}^n w_i^2 = \frac{\sigma^2}{\sum x_i^2}\end{aligned}\quad (2-13)$$

زیرا $E(u_i u_j)$ طبق فرض عدم خودهمبستگی u_i ها، برابر با صفر است^۲. واریانس $\hat{\beta}$ را به صورت زیر بازنویسی می‌کنیم:

^۱ روابط $\sum x_i y_i = \sum x_i Y_i = \sum X_i y_i$ و $\sum x_i X_i = \sum x_i^2$ ، $\sum x_i = 0$ را می‌باشد.

^۲ توجه شود که $\sum w_i^2$ برابر است با:

$$\sum w_i^2 = \sum \left(\frac{x_i}{\sum x_i^2} \right)^2 = \frac{\sum x_i^2}{(\sum x_i^2)^2} = \frac{1}{\sum x_i^2}$$

$$\text{var}(\hat{\beta}) = \frac{\sigma^2/n}{\sum x_i^2/n} = \frac{\sigma^2/n}{S_x^2}$$

چون S_x^2 مقدار معینی دارد و با افزایش حجم نمونه نیز مقدار آن معلوم و معین است، لذا خواهیم داشت:

$$\lim_{n \rightarrow \infty} \text{var}(\hat{\beta}) = \frac{\lim \sigma^2/n}{\lim S_x^2} = 0$$

زیرا $\lim \sigma^2/n$ برابر صفر است. بنابراین، $\hat{\beta}$ یک تخمین زننده سازگار است.

۴-۷-۲ حداقل واریانس

قضیه گوس-مارکف بیان می‌دارد که از بین تمامی تخمین‌زننده‌های خطی و بدون تورش، روش OLS کمترین واریانس را دارد. بدین منظور، مشابه با (۲-۱۱) تخمین‌زننده خطی دیگری مانند $\tilde{\beta}$ را در نظر بگیرید:

$$\tilde{\beta} = \sum a_i Y_i = \sum a_i (\alpha + \beta X_i + u_i) = \alpha \sum a_i + \beta \sum a_i X_i + \sum a_i u_i$$

امید ریاضی $\tilde{\beta}$ عبارت است از:

$$E(\tilde{\beta}) = \alpha \sum a_i + \beta \sum a_i X_i$$

برای اینکه $\tilde{\beta}$ بدون تورش باشد بایستی شرط $\sum a_i = 0$ و $\sum a_i X_i = 1$ برقرار باشد. واریانس $\tilde{\beta}$ برابر است با:

$$\text{var}(\tilde{\beta}) = E(\tilde{\beta} - \beta)^2 = E\left(\sum a_i u_i\right)^2 = E\left(\sum a_i^2 u_i^2\right) = \sigma^2 \sum a_i^2$$

با توجه به اینکه a_i با w_i متفاوت است، لذا آن را به صورت $a_i = w_i + b_i$ می‌نویسیم (توجه شود که چون $\sum a_i = \sum w_i = 0$ و $\sum a_i X_i = \sum w_i X_i = 1$ است، لذا بایستی $\sum b_i X_i = 0$ باشد):

$$\begin{aligned} \text{var}(\tilde{\beta}) &= \sigma^2 \sum a_i^2 = \sigma^2 \sum (w_i + b_i)^2 \\ &= \sigma^2 \sum (w_i^2 + b_i^2) = \sigma^2 \sum w_i^2 + \sigma^2 \sum b_i^2 = \text{var}(\hat{\beta}) + \sigma^2 \sum b_i^2 \end{aligned}$$

چون $\sigma^2 \sum b_i^2$ غیر منفی است لذا $\text{var}(\tilde{\beta}) \geq \text{var}(\hat{\beta})$ می‌باشد و نتیجه می‌شود که تخمین‌زننده OLS کاراتر است.

۲-۷-۵ توزیع تخمین‌زننده‌های OLS

امید ریاضی و واریانس $\hat{\beta}$ نشان می‌دهد که تخمین‌زننده بدون تورش و با حداقل واریانس برای β است. از طرف دیگر چون $\hat{\beta}$ تابع خطی از u_i است لذا $\hat{\beta}$ نیز یک متغیر تصادفی با توزیع نرمال می‌باشد. مشابه این محاسبات را برای $\hat{\alpha}$ نیز می‌توان انجام داد.^۱ بدین ترتیب مشخصات تخمین‌زننده‌های OLS عبارت است از:

$$\begin{aligned}\hat{\beta} &= \beta + \sum w_i u_i, & w_i &= \sum \left(\frac{x_i}{\sum x_i^2} \right) \\ \hat{\alpha} &= \alpha + \sum k_i u_i, & k_i &= \frac{1}{n} - \bar{X} \frac{x_i}{\sum x_i^2} \\ \hat{\beta} &\sim N\left(\beta, \frac{\sigma^2}{\sum x_i^2}\right), & \hat{\alpha} &\sim N\left(\alpha, \left(\frac{1}{n} + \frac{\bar{X}^2}{\sum x_i^2}\right)\sigma^2\right)\end{aligned}\quad (۲-۱۴)$$

۲-۷-۶ همبستگی $\hat{\alpha}$ و $\hat{\beta}$

همبستگی تخمین‌زننده‌های $\hat{\alpha}$ و $\hat{\beta}$ باعث می‌شود که تغییر یکی بر دیگری تأثیر بگذارد. بدین منظور کوواریانس $\hat{\alpha}$ و $\hat{\beta}$ را حساب می‌کنیم:

$$\text{cov}(\hat{\alpha}, \hat{\beta}) = E[(\hat{\alpha} - \alpha)(\hat{\beta} - \beta)]$$

به جای $\hat{\alpha} - \alpha$ و $\hat{\beta} - \beta$ از (۲-۱۴) قرار می‌دهیم:

$$E[(\hat{\alpha} - \alpha)(\hat{\beta} - \beta)] = E\left[\sum_i k_i u_i \left[\sum_i w_i u_i\right]\right]$$

چون امید ریاضی $u_i u_j$ به ازای $i \neq j$ برابر صفر است، لذا خواهیم داشت:

$$E[(\hat{\alpha} - \alpha)(\hat{\beta} - \beta)] = E\left[\sum_i k_i w_i u_i^2\right] = \sigma^2 \sum_i k_i w_i$$


به جای k_i و w_i از (۴-۱۴) قرار داده و آن را ساده می‌کنیم که طبق آن، خواهیم داشت:

^۱ برای محاسبه امید ریاضی و واریانس $\hat{\alpha}$ لازم است آن را به صورت زیر بنویسیم:


$$\begin{aligned}\hat{\alpha} &= \bar{Y} - \bar{X}\hat{\beta} = \frac{\sum Y_i}{n} - \bar{X} \frac{\sum x_i Y_i}{\sum x_i^2} \\ &= \sum \left(\frac{1}{n} - \bar{X} \frac{x_i}{\sum x_i^2} \right) Y_i = \sum k_i Y_i, \quad k_i = \frac{1}{n} - \frac{\bar{X} x_i}{\sum x_i^2} \\ &= \sum k_i (\alpha + \beta x_i + u_i) = \alpha + \sum k_i u_i, \quad \sum k_i x_i = 0, \quad \sum k_i = 1\end{aligned}$$

$$\text{cov}(\hat{\alpha}, \hat{\beta}) = -\bar{X} \frac{\sigma^2}{\sum x_i^2} = -\bar{X} \text{var}(\hat{\beta}) \quad (2-15)$$

مقدار این کوواریانس، منفی است و بدان معنا است که مثلاً اگر X را حذف کنیم معادل با آن است که β را برابر با صفر قرار داده‌ایم و این منجر به افزایش $\hat{\alpha}$ می‌شود (البته مشروط به آن که $\beta \geq 0$ باشد). یعنی یک معادله با شیب مثبت را تبدیل به یک خط افقی با شیب صفر کرده‌ایم که عرض از مبدأ آن افزایش می‌یابد.



ولی اگر $\beta \leq 0$ باشد، آنگاه حذف X و صفر قرار دادن β موجب می‌شود که یک رگرسیون نزولی را تبدیل به یک رگرسیون افقی کنیم. بنابراین، β را افزایش داده‌ایم (از منفی به صفر) و لذا $\hat{\alpha}$ کاهش می‌یابد (چون کوواریانس $\hat{\alpha}$ و $\hat{\beta}$ منفی است).



همچنین می‌توان اثر حذف $\hat{\alpha}$ بر $\hat{\beta}$ را نیز بررسی نمود که این موضوع در فصل چهارم بررسی شده است.

۸-۲ تغییرات کل^۱، تغییرات توضیح داده شده^۲ و تغییرات توضیح داده نشده^۳

تغییرات کل Y بیانگر مجموع مجذور تغییرات Y حول \bar{Y} است:

$$Y \text{ تغییرات کل} = \sum (Y_i - \bar{Y})^2 = \sum y_i^2 = TSS$$

تغییرات توضیح داده شده بیانگر آن بخش از تغییرات Y است که توسط معادله رگرسیون، توضیح داده می‌شود:

$$Y \text{ تغییرات توضیح داده شده} = \sum (\hat{Y}_i - \bar{Y})^2 = \sum \hat{y}_i^2 = ESS$$

تغییرات توضیح داده نشده بیانگر آن بخش از تغییرات Y است که ناشی از سایر عوامل است که برابر با مجموع مجذور خطاها است:

$$Y \text{ تغییرات توضیح داده نشده یا خطاها یا باقیمانده‌ها} = \sum (Y_i - \hat{Y}_i)^2 = \sum e_i^2 = RSS$$

بدیهی است که رابطه $TSS = ESS + RSS$ برقرار است. بدین منظور توجه شود که اگر از $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$ به جای $\hat{\alpha}$ در معادله $\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$ قرار دهیم، رابطه $\hat{Y}_i - \bar{Y} = \hat{\beta}(X_i - \bar{X})$ به دست می‌آید که بر اساس آن، ESS عبارت است از:

$$ESS = \sum (\hat{Y}_i - \bar{Y})^2 = \hat{\beta}^2 \sum x_i^2 = \hat{\beta}^2 \sum x_i y_i$$

از طرف دیگر اگر در معادله $Y_i = \hat{Y}_i + e_i = \hat{\alpha} + \hat{\beta}X_i + e_i$ به جای $\hat{\alpha}$ قرار دهیم، نتیجه $Y_i - \bar{Y} = \hat{\beta}(X_i - \bar{X}) + e_i$ یا $y_i = \hat{\beta}x_i + e_i$ به دست می‌آید. لذا TSS عبارت است از:

$$\begin{aligned} TSS &= \sum (Y_i - \bar{Y})^2 = \sum y_i^2 = \sum (\hat{\beta}x_i + e_i)^2 \\ &= \hat{\beta}^2 \sum x_i^2 + \sum e_i^2 + 2\hat{\beta} \sum x_i e_i \\ &= \hat{\beta}^2 \sum x_i^2 + \sum e_i^2 = ESS + RSS \end{aligned} \quad (2-16)$$

عبارت $\sum x_i e_i$ برابر با صفر است، زیرا $\sum x_i e_i = \sum (X_i - \bar{X})e_i = \sum e_i X_i - \bar{X} \sum e_i$ بوده و طبق معادلات (۲-۹)، این دو جمله برابر با صفر می‌باشند.

^۱TSS=Total Sum of Squares

^۲ESS= Explained Sum of Squares

^۳RSS=Residual Sum of Squares

۲-۹ ضریب تعیین (R^2)

بعد از تخمین معادله رگرسیون، اولین سؤال این است که تا چه اندازه تخمین \hat{Y}_i به Y_i نزدیک است. به عبارت دیگر، چقدر معادله رگرسیون تخمینی، معادله خوبی است و می تواند تغییرات Y را توضیح دهد. در اینجا از معیاری به نام «ضریب تعیین» استفاده می شود که بیانگر نسبت تغییرات توضیح داده شده (ESS) به تغییرات کل است:

$$R^2 = \frac{ESS}{TSS}$$

با جایگذاری به جای TSS و ESS خواهیم داشت:

$$R^2 = \frac{ESS}{TSS} = \frac{\sum \hat{y}_i^2}{\sum y_i^2} = \frac{\hat{\beta}^2 \sum x_i^2}{\sum y_i^2} = \frac{\hat{\beta} \sum x_i y_i}{\sum y_i^2} \quad (2-17)$$

اگر به جای $\hat{\beta}$ قرار دهیم نتیجه می شود که ضریب تعیین برابر با مجذور ضریب همبستگی است. همچنین می توان ضریب تعیین را به صورت زیر نوشت:

$$R^2 = \frac{ESS}{TSS} = \frac{TSS - RSS}{TSS} = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum e_i^2}{\sum y_i^2}$$

بدین ترتیب R^2 بیانگر قدرت توضیح دهندگی یا ضریب خوبی مدل می باشد. همان طور که گفته شد، R^2 معیاری برای قدرت توضیح دهندگی معادله رگرسیون است. یعنی نشان می دهد که \hat{Y}_i ها تا چه اندازه همسو با Y_i ها هستند. لذا R^2 برابر با مجذور ضریب همبستگی بین \hat{Y}_i و Y_i است. بدین منظور ابتدا ESS را به صورت زیر می نویسیم:

$$\begin{aligned} ESS &= \sum \hat{y}_i^2 = \sum \hat{y}_i \hat{y}_i = \sum \hat{y}_i (y_i - e_i) \quad ; \quad y_i = \hat{y}_i + e_i \\ &= \sum \hat{y}_i y_i + \sum \hat{y}_i e_i = \sum \hat{y}_i y_i \end{aligned}$$

که $\sum \hat{y}_i e_i = 0$ است.^۱ حال R^2 را به صورت زیر می نویسیم:

^۱ با استفاده از $\hat{y}_i = \hat{\beta} x_i$ خواهیم داشت:

$$\sum \hat{y}_i e_i = \sum \hat{\beta} x_i e_i = \hat{\beta} \sum x_i e_i = 0$$

طبق معادلات نرمال، $\sum x_i e_i = 0$ است.

$$R^2 = \frac{ESS}{TSS} = \frac{(ESS)^2}{(TSS)(ESS)} = \frac{(\sum \hat{y}_i y_i)^2}{\sum (y_i^2)(\sum \hat{y}_i^2)} = r_{\hat{y}y}^2$$

بنابراین R^2 برابر با مجذور ضریب همبستگی بین \hat{Y} و Y است.

مثال ۲-۳: در مثال ۲-۲ ضریب تعیین را محاسبه کنید:

$$\begin{aligned} R^2 &= \frac{ESS}{TSS} \\ ESS &= \hat{\beta}^2 \sum x_i^2 = (1/36)^2 (158/8) = 30.2/57 \\ TSS &= \sum y_i^2 = 3338 - 20(12/1)^2 = 40.9/8 \\ R^2 &= \frac{30.2/57}{40.9/8} = 0.738 \end{aligned}$$

بنابراین رگرسیون تخمینی توانسته است حدود ۷۳/۸ درصد از تغییرات Y را توضیح دهد و بقیه آن ناشی از عوامل تصادفی (u) می‌باشد.

۲-۱۰ میانگین خطای تخمین یا انحراف معیار رگرسیون ($\hat{\sigma}$)

میانگین خطای تخمین یا انحراف معیار رگرسیون، میزان پراکندگی مشاهدات را در اطراف خط رگرسیون نشان می‌دهد. وقتی خط رگرسیون به مشاهدات واقعی نزدیکتر باشد، خطای کمتری دارد و لذا انحراف معیار کوچکتر است. به‌طور کلی، انحراف معیار معادلات رگرسیون بیانگر متوسط خطای معادله رگرسیون است. خطای معادله رگرسیون را می‌توان با محاسبه واریانس شرطی Y یا واریانس جمله خطا، محاسبه نمود که برابر با تخمین $\hat{\sigma}^2$ است.

برای محاسبه $\hat{\sigma}^2$ لازم است که ابتدا $\sum (e_i - \bar{e})^2 = \sum e_i^2$ را حساب کنیم. بدین منظور معادله $Y_i = \alpha + \beta X_i + u_i$ را جمع زده و به‌صورت $\sum Y_i = n\alpha + \beta \sum X_i + \sum u_i$ می‌نویسیم که با تقسیم آن بر n ، معادله $\bar{Y} = \alpha + \beta \bar{X} + \bar{u}$ به‌دست می‌آید. حال معادله زیر را به‌دست می‌آوریم:

$$Y_i - \bar{Y} = (\alpha + \beta X_i + u_i) - (\alpha + \beta \bar{X} + \bar{u}) = \beta(X_i - \bar{X}) + (u_i - \bar{u})$$

$$y_i = \beta x_i + (u_i - \bar{u})$$

از طرف دیگر، چون $\bar{Y} = \hat{\bar{Y}}$ است، خطای تخمین را به‌صورت زیر می‌نویسیم:

$$\begin{aligned} e_i &= Y_i - \hat{Y}_i = (Y_i - \bar{Y}) - (\hat{Y}_i - \bar{Y}) = y_i - \hat{y}_i \\ &= \beta x_i + (u_i - \bar{u}) - \hat{\beta} x_i = -(\hat{\beta} - \beta)x_i + (u_i - \bar{u}) \end{aligned}$$

مجموع مجذور خطاها برابر است با:

$$\begin{aligned}\sum e_i^2 &= \sum \left[-(\hat{\beta} - \beta)x_i + (u_i - \bar{u}) \right]^2 \\ &= (\hat{\beta} - \beta)' \sum x_i^2 + \sum (u_i - \bar{u})^2 - 2(\hat{\beta} - \beta)' \sum x_i(u_i - \bar{u})\end{aligned}$$

امید ریاضی $\sum e_i^2$ برابر است با (در جمله سوم از رابطه $\hat{\beta} - \beta = \sum x_i u_i$ و $\sum x_i(u_i - \bar{u}) = \sum x_i u_i$ استفاده شده است).

$$E(\sum e_i^2) = \sum x_i^2 E(\hat{\beta} - \beta)' + E\left[\sum (u_i - \bar{u})^2\right] + 2E\left[\left(\sum x_i u_i\right)\left(\sum x_i u_i\right)'\right] \quad (2-18)$$

حال امید ریاضی هر یک از عبارت‌های فوق را حساب می‌کنیم:

$$\begin{aligned}E(\hat{\beta} - \beta) &= \text{var}(\hat{\beta}) = \frac{\sigma^2}{\sum x_i^2} \\ E\left[\sum (u_i - \bar{u})^2\right] &= \sigma^2 E\left[\sum \left(\frac{u_i - \bar{u}}{\sigma}\right)^2\right] = \sigma^2 E(\chi_{n-1}^2) = \sigma^2(n-1) \\ E\left[\left(\sum x_i u_i\right)\left(\sum x_i u_i\right)'\right] &= E\left(\sum x_i x_i u_i^2 + \dots\right) = E\left(\sum x_i x_i u_i^2\right) \\ &= E\left(\sum \frac{x_i}{\sum x_i^2} x_i u_i^2\right) = E\left(\frac{\sum x_i^2 u_i^2}{\sum x_i^2}\right) = \frac{\sum x_i^2 E(u_i^2)}{\sum x_i^2} = \frac{\sum x_i^2 \sigma^2}{\sum x_i^2} = \sigma^2\end{aligned}$$

در محاسبه امید ریاضی جمله آخر، امید ریاضی حاصل ضرب‌های متقاطع برابر صفر است، زیرا شامل حاصل ضرب‌هایی به شکل $u_i u_j$ است که امید ریاضی آنها صفر است (فرض عدم خودهمبستگی). بنابراین، با جایگذاری در (2-18) خواهیم داشت:

$$E(\sum e_i^2) = \sum x_i^2 \frac{\sigma^2}{\sum x_i^2} + (n-1)\sigma^2 - 2\sigma^2 = \sigma^2 + (n-1)\sigma^2 - \sigma^2 = (n-1)\sigma^2 \quad (2-19)$$

با تقسیم طرفین بر $n-1$ ، خواهیم داشت:

$$\sigma^2 = \frac{E(\sum e_i^2)}{n-1}$$

بنابراین تخمین σ^2 برابر است با:

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-1} \quad (2-20)$$

بدین ترتیب $\hat{\sigma}^2$ تخمین زننده بدون تورش σ^2 است، زیرا طبق (2-19) خواهیم داشت:

$$E(\hat{\sigma}^2) = E\left(\frac{\sum e_i^2}{n-2}\right) = \frac{E(\sum e_i^2)}{n-2} = \frac{(n-2)\sigma^2}{n-2} = \sigma^2 \quad (2-21)$$

e_i از رابطه $e_i = Y_i - (\hat{\alpha} + \hat{\beta} X_i)$ محاسبه می‌شود که نیاز به $\hat{\alpha}$ و $\hat{\beta}$ داریم. اما چون برای برآورد $\hat{\alpha}$ و $\hat{\beta}$ از روابط $\sum e_i = 0$ و $\sum e_i X_i = 0$ استفاده شده است، لذا به دلیل وجود این دو محدودیت، درجه آزادی $\sum e_i$ برابر $n-2$ خواهد شد. به هر حال، $\hat{\sigma}^2$ انحراف معیار تخمین است و نشان می‌دهد که به طور متوسط Y های واقعی چه قدر از Y های تخمینی (\hat{Y}) انحراف دارد.

مثال ۴-۴: در مثال ۲-۲ خطای معادله رگرسیون را محاسبه کنید.

در این مثال مقادیر زیر را داریم:

$$TSS = \sum y_i^2 = 40.9/8$$

$$ESS = \hat{\beta}^2 \sum x_i^2 = (1/38)^2 (158/8) = 30.2/57$$

$$RSS = TSS - ESS = 40.9/8 - 30.2/57 = 10.7/23$$

$$\hat{\sigma}^2 = \frac{RSS}{n-2} = \frac{10.7/23}{18} = 5/957$$

$$\hat{\sigma} = \sqrt{5/957} = 2/44$$

$\hat{\sigma} = 2/44$ بیانگر آن است که انحراف Y واقعی از تخمینی، به طور متوسط

۲/۴۴ است.

۲-۱۱ آزمون معنادار بودن ضرایب رگرسیون

این آزمون بیانگر این است که آیا ضرایب رگرسیون واقعاً از صفر متفاوت هستند یا خیر. با استفاده از مقادیر $\hat{\alpha}$ و $\hat{\beta}$ ، می‌توان این آزمون‌ها را به سادگی انجام داد. این آزمون برای β به صورت آزمون فرضیه $H_0: \beta = 0$ در مقابل فرضیه $H_1: \beta \neq 0$ می‌باشد که برای آزمون آن از توزیع t استفاده می‌شود (زیرا $\hat{\beta}$ توزیع نرمال با میانگین β و واریانس $\sigma^2 / \sum x_i^2$ دارد که در صورت مجهول بودن σ^2 تبدیل به توزیع t می‌شود):

$$t_{n-2} = \frac{\hat{\beta} - \beta}{\sqrt{\text{var}(\hat{\beta})}} \Big|_{H_0} = \frac{\hat{\beta}}{\frac{\hat{\sigma}}{\sqrt{\sum x_i^2}}} = \sqrt{\sum x_i^2} \frac{\hat{\beta}}{\hat{\sigma}} \quad (2-22)$$

اگر قدرمطلق t از t جدول بیشتر باشد، فرضیه $H_0: \beta = 0$ رد می‌شود و بیانگر معنی‌دار بودن ضریب رگرسیون است. به طور کلی هر یک از ضرایب معادله رگرسیون در صورتی در سطح ۹۵

درصد معنی‌دار هستند که برای هر یک از آنها (به شرطی که حجم نمونه به اندازه کافی بزرگ (حدود ۳۰) باشد)، تقریباً $|t| \geq 2$ باشد.

برای آزمون معنی‌دار بودن α نیز می‌توان فرضیه $H_0: \alpha = 0$ را در مقابل $H_1: \alpha \neq 0$ آزمون نمود که در این حالت آماره t عبارت است از:

$$t_{n-1} = \frac{\hat{\alpha} - \alpha}{\sqrt{\text{var}(\hat{\alpha})}} \Big|_{H_0} = \frac{\hat{\alpha}}{\hat{\sigma} \sqrt{1 + \frac{\bar{X}^2}{\sum x_i^2}}} \quad (2-23)$$

مثال ۴-۵: در مثال ۲-۲ آزمون معنی‌دار بودن ضرایب رگرسیون را انجام دهید.

ابتدا $\hat{\sigma}^2$ را حساب می‌کنیم که در مثال ۲-۴ برابر با ۲/۴۴۱ به دست آمد. مقدار t برای آزمون فرضیه $H_0: \beta = 0$ برابر است با:

$$t = \sqrt{158/8} \frac{1/38}{2/441} = 7/127$$

از آنجا که مقدار $t = 7/127$ از t جدول (در اینجا حجم نمونه $n=20$ است و لذا t جدول برابر با ۲/۰۹ می‌باشد) بزرگتر است و در ناحیه بحرانی قرار گرفته لذا فرضیه $\beta = 0$ رد می‌شود و در نتیجه β تفاوت معناداری با صفر دارد. مقدار t برای آزمون $\alpha = 0$ عبارت است از:

$$t = \frac{3/266}{\sqrt{2/441 \left(1 + \frac{(6/4)^2}{158/8} \right)}} = 2/411$$

چون مقدار $t = 2/411$ از t جدول یعنی ۲/۰۹ بزرگتر است و در ناحیه بحرانی قرار گرفته است، لذا فرضیه $\alpha = 0$ رد می‌شود و در نتیجه، α تفاوت معناداری با صفر دارد.

این آزمون‌ها را می‌توان برای فرضیه‌هایی مانند $\beta = 1$ یا $\beta = 5$ و غیره نیز انجام داد. مراحل انجام این آزمون‌ها تفاوتی با آزمون فرضیه $\beta = 0$ ندارد.

مثال ۴-۶: در مثال ۲-۲ آیا β می‌تواند برابر با ۱ باشد؟

در اینجا فرضیه $\beta = 1$ را در مقابل $\beta \neq 1$ آزمون می‌کنیم. مقدار t برابر است با:

$$t = \sqrt{158/8} \frac{1/38 - 1}{2/441} = 1/96$$

چون مقدار t در ناحیه بحرانی قرار نگرفته است لذا فرضیه $\beta = 1$ رد نمی‌شود. بنابراین β تفاوت معناداری با ۱ ندارد.

برای ضرایب α و β می‌توان فاصله اطمینان نیز تشکیل داد که با استفاده از آماره t به دست می‌آید. برای آزمون فرضیه در مورد β ، ناحیه قبول فرضیه H_0 به صورت زیر است:

$$|t| \leq t_{\alpha/2, n-2} \Rightarrow \left| \frac{\hat{\beta} - \beta}{\hat{\sigma} / \sqrt{\sum x_i^2}} \right| \leq t_{\alpha/2, n-2}$$

با ساده کردن این نامساوی، می‌توان تخمین فاصله‌ای را برای β و مشابه آن را برای α به دست آورد:

$$\left(\hat{\beta} - t_{\alpha/2, n-2} \frac{\hat{\sigma}}{\sqrt{\sum x_i^2}} \leq \beta \leq \hat{\beta} + t_{\alpha/2, n-2} \frac{\hat{\sigma}}{\sqrt{\sum x_i^2}} \right) \quad (2-24)$$

$$\left(\hat{\alpha} - t_{\alpha/2, n-2} \hat{\sigma} \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum x_i^2}} \leq \alpha \leq \hat{\alpha} + t_{\alpha/2, n-2} \hat{\sigma} \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum x_i^2}} \right)$$

مثال ۲-۲: تخمین فاصله‌ای ۹۵ درصد را برای β در مثال ۲-۱ به دست آورید.

محاسبات لازم برای تعیین فاصله اطمینان، در مثال ۲-۱ تا ۲-۵ انجام شده است که عبارتند از:

$$\hat{\beta} = 1/38 \quad \sum x_i^2 = 158/8$$

$$\hat{\sigma}^2 = 5/957 \quad n = 20$$

با توجه به $t_{1/2, 18} = 1/2$ و انجام محاسبات لازم، تخمین فاصله‌ای برای β عبارت است از:

$$(0/978, 1/782)$$

بنابراین با احتمال ۹۵ درصد β در این فاصله قرار دارد.

۲-۱۲ تحلیل واریانس (آزمون معنادار بودن رگرسیون)

تحلیل واریانس روش دیگری برای بررسی وضعیت مدل رگرسیون است. در تحلیل واریانس، عوامل مؤثر بر Y به دو دسته تقسیم می‌شوند. یکی ناشی از X (جزء غیر تصادفی یا قابل کنترل) که برابر با $\alpha + \beta X$ است و دیگری ناشی از اثر سایر عوامل یعنی u (جزء تصادفی یا غیر قابل کنترل) می‌باشد. حال سؤال این است که آیا اثرات ناشی از X یا عاملی که قابل کنترل است در

مقایسه با سایر عوامل یعنی u در خور توجه است یا خیر. این سؤال معادل با این است که اگر $\beta = 0$ باشد، بدان معنا است که X بی تأثیر است و تغییرات Y عملاً ناشی از تغییرات تصادفی است. لذا بحث فوق معادل است با آزمون این فرضیه که آیا β تفاوت معناداری با صفر دارد یا خیر.^۱

همان طور که اشاره شد، کل تغییرات Y برابر با «تغییرات توضیح داده شده» به علاوه «تغییرات توضیح داده نشده» می باشد که اولی ناشی از X و دومی ناشی از u است:

$$TSS = ESS + RSS$$

$$\sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum e_i^2 \quad (2-25)$$

اما هر یک از جملات رابطه (۲-۲۵) را می توان برحسب توزیع χ^2 نوشت. زیرا شامل متغیرهایی هستند که دارای توزیع نرمال بوده Y_i و \hat{Y}_i هر کدام توزیع نرمال دارند، زیرا تابع خطی از u_i هستند) و به صورت مجذور نیز بیان شده اند.

$$TSS = \sum y_i^2, \quad ESS = \sum \hat{y}_i^2, \quad RSS = \sum e_i^2 = \sum (Y_i - \hat{Y}_i)^2$$

TSS شامل n متغیر Y_i می باشد. اما به دلیل محدودیت $\sum (Y_i - \bar{Y}) = 0$ درجه آزادی آن $n-1$ می باشد. ESS تابعی از \hat{Y}_i است که آن نیز فقط تابعی از دو متغیر تصادفی $\hat{\alpha}$ و $\hat{\beta}$ است و به دلیل اینکه $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$ است لذا درجه آزادی آن برابر با ۱ خواهد شد. RSS نیز تابعی از n متغیر تصادفی e_i است. اما چون دو محدودیت به صورت $\sum e_i = 0$ و $\sum e_i X_i = 0$ دارد، لذا درجه آزادی آن $n-2$ است.

حال می توان ESS (یعنی اثر X) را با RSS (اثر سایر عوامل یا u) مقایسه نمود. بدین منظور ابتدا میانگین آنها را محاسبه کرده و سپس از نسبت آنها، تابع F را تعریف می کنیم:

۱- در فصل سوم خواهیم دید که در رگرسیون چند متغیره، آزمون معنادار بودن رگرسیون با آزمون معنی دار بودن ضریب β ، متفاوت است.

۲ توجه شود که طبق رابطه (۱-۳۰) در فصل اول، روابط زیر برقرار است:

$$\frac{TSS}{\sigma^2} = \frac{\sum y_i^2}{\sigma^2} = \chi_{n-1}^2, \quad \frac{ESS}{\sigma^2} = \frac{\sum \hat{y}_i^2}{\sigma^2} = \chi_1^2, \quad \frac{RSS}{\sigma^2} = \frac{\sum e_i^2}{\sigma^2} = \chi_{n-2}^2$$

$$S_E^2 = \frac{ESS}{1}, \quad S_R^2 = \hat{\sigma}^2 = \frac{RSS}{n-2} = \frac{\sum e_i^2}{n-2}$$

$$F_{1, n-2} = \frac{\frac{\chi_1^2}{1}}{\frac{\chi_{n-2}^2}{n-2}} = \frac{\frac{\sigma^2 \chi_1^2}{1}}{\frac{\sigma^2 \chi_{n-2}^2}{n-2}} = \frac{S_E^2}{S_R^2} = \frac{ESS}{RSS} = (n-2) \frac{ESS}{RSS} \quad (2-26)$$

بدیهی است که اگر مقدار F بزرگ باشد، نشان می‌دهد که معادله رگرسیون توانسته است بخشی از تغییرات Y را توضیح دهد و از نظر آماری معنادار است، زیرا بزرگ بودن F بدین معنی است که تأثیر X در مقایسه با سایر عوامل (u) درخور توجه است.

از طرف دیگر می‌توان F را بر حسب R^2 نیز بیان نمود:

$$F = (n-2) \frac{ESS}{RSS} = (n-2) \frac{ESS}{TSS - ESS}$$

$$= (n-2) \frac{ESS/TSS}{1 - ESS/TSS} = (n-2) \frac{R^2}{1 - R^2} \quad (2-27)$$

بنابراین هر چقدر R^2 بیشتر باشد، مقدار F نیز بیشتر خواهد شد. به هر حال مزیت آزمون F در این است که با استفاده از آن می‌توان معنادار بودن رگرسیون‌های چندمتغیره را نیز آزمون نمود.^۱

مثال ۱۰-۲: در مثال ۲-۲ آیا رگرسیون Y روی X معنادار است یا خیر.

چون $ESS = ۱۵/۵۵۸$ و $TSS = ۲۴/۸۳۳$ لذا $RSS = ۲۴/۸۳۳ - ۱۵/۵۵۸ = ۹/۲۷۵$ است. بر این اساس مقدار F برابر است با:

$$F = (n-2) \frac{ESS}{RSS} = (20-2) \frac{۳۰۲/۵۷}{۱۰۷/۲۳} = ۵۰/۷۹$$

$$(F \geq_{\alpha, 1, n-2} = F_{1, 0.05, 18} = ۸/۲۹)$$

چون $F = ۵۰/۷۹$ از F جدول (۸/۲۹) بزرگتر است، لذا فرضیه H_0 رد می‌شود.

به عبارت دیگر X توانسته است به‌طور معناداری تغییرات Y را توضیح دهد.

^۱ توجه شود که در رگرسیون یک متغیره، چون دوجه آزادی صورت F برابر با ۱ است، لذا F برابر با مجذور t در آزمون فرضیه $H_0: \beta = 0$ است.

۱۳-۲ جمع‌بندی و تحلیل نتایج رگرسیون

در تحلیل رگرسیون، متناسب با موضوع مورد نظر، ابتدا معادله را انتخاب می‌کنیم که ممکن است خطی یا غیرخطی باشد. سپس ضرایب آن را با روش حداقل مربعات معمولی (OLS) برآورد می‌کنیم. برای این معادله، معیارهایی از قبیل معنی‌دار بودن ضرایب، ضریب تعیین و مقدار F محاسبه می‌شوند که همراه با هر معادله رگرسیون، ارائه می‌گردند. در مثال زیر، این معیارها و تفسیر مختصر آنها ارائه شده است.

مثال ۱۱-۲: نتایج حاصل از مثال ۲-۲ به‌طور خلاصه عبارت است از:

$$\hat{Y}_i = 3/266 + 1/38 X_i \quad R^2 = 0/738$$

$$(2/4) \quad (7/1) \quad F = 50/79$$

R^2 بیانگر این است که معادله تخمینی توانسته است حدود ۷۳/۸ درصد از تغییرات متغیر وابسته (Y) را توضیح دهد ولی ۲۶/۲ درصد از تغییرات Y ناشی از عوامل تصادفی است که این معادله نتوانسته آنها را به حساب آورد. به عبارت دیگر، ۷۳/۸ درصد از تغییرات Y توسط X توضیح داده می‌شود و بقیه تغییرات آن ناشی از سایر عوامل است که در داخل u قرار دارند. مقدار F نیز نشان می‌دهد که این معادله کاملاً معنی‌دار است زیرا از F جدول بیشتر می‌باشد.

ارقام داخل پرانتز بیانگر مقدار t برای هر یک از این ضرایب می‌باشد که وضعیت معنی‌دار بودن آنها را نشان می‌دهد. مقدار t برای β بیشتر از ۲ است، لذا معنی‌دار می‌باشد (به عبارت دیگر به‌طور معنی‌داری از صفر تفاوت دارد). همچنین چون مقدار t برای α بیشتر از ۲ است، لذا معنی‌دار بوده و با صفر تفاوت دارد.

برآورد رگرسیون ساده با Eviews

فایل data1

برای برآورد معادله رگرسیون، به دو صورت می‌توان عمل نمود. یک روش این است که در سطر فرمان یا فرمان LS، معادله مورد نظر را به صورت $LS \ Y \ C \ X$ وارد نماییم. LS فرمان اجرای روش حداقل مربعات معمولی است. در اینجا Y متغیر وابسته، C عرض از مبدأ و X متغیر توضیحی را نشان می‌دهد. بعد از وارد نمودن عبارت مذکور با زدن کلید Enter نتایج تخمین در پنجره Equation ارائه می‌شود.

همچنین می‌توان از منوی Quick گزینه Estimation Equation را انتخاب نمود که به دنبال آن پنجره زیر باز می‌شود:

Equation Estimation

Specification Options

Equation specification

Dependent variable followed by list of regressors including ARMA and PDL terms, OR an explicit equation like $Y=c(1)+c(2)*X$.

Estimation settings

Method: LS - Least Squares (NLS and ARMA)

Sample: 1345 1380

OK Cancel

در اینجا معادله مورد نظر را به صورت $Y = C + X$ و یا به صورت $Y = C(1) + C(2)*X$ وارد نموده و OK را انتخاب می‌کنیم. در قسمت پایین این پنجره، روش‌های تخمین نیز مشخص شده است که در گزینه Method قرار دارند. گزینه Sample نیز می‌تواند دورهای است که می‌خواهیم معادله را برای آن دوره برآورد نماییم. به عنوان نمونه، نتایج تخمین معادله سرمایه‌گذاری بخش خصوصی به قیمت ثابت (IP) روی نرخ بهره حقیقی (RR) برای دوره ۱۳۴۵-۷۵ به صورت زیر می‌باشد.

Equation: UNTITLED Workfile: ST::Untitled

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: IP									
Method: Least Squares									
Date 02/03/11 Time: 09:38									
Sample 1345 1385									
Included observations: 21									
Variable	Coefficient	Std. Error	t-Statistic	Prob					
C	20131.31	2507.801	7.779914	0.0000					
RR	-844.9209	324.5470	-2.603385	0.0175					
R-squared	0.262928	Mean dependent var		22847.13					
Adjusted R-squared	0.224133	S.D. dependent var		12319.65					
S.E. of regression	10851.55	Akaike info criterion		21.51240					
Sum squared resid	2.24E+09	Schwarz criterion		21.61188					
Log likelihood	-223.8802	Hannan-Quinn criter		21.53399					
F-statistic	6.777613	Durbin-Watson stat		1.177749					
Prob(F-statistic)	0.017458								


همان‌طور که ملاحظه می‌شود در بالای این جدول، نام متغیر وابسته مشخص شده است. سپس روش تخمین با عبارت Least Squares نشان داده شده است. در سطر بعدی، زمان انجام این تخمین و سپس دوره زمانی در مقابل Sample ارائه شده است. تعداد مشاهدات نیز مشخص شده که برابر با ۲۱ می‌باشد.

در قسمت بعد ابتدا ستون Variable را داریم که در این ستون نام متغیرهای توضیحی ارائه می‌شود. C یا اگر عرضی از مبدأ و RR نیز نوع بهره حقیقی است. در ستون دوم که تحت عنوان Coefficient است مقدار ضرایب را نشان می‌دهد که مقدار عرضی از مبدأ $20131/31$ و ضریب نوع بهره یا شیب معادله رگرسیون برابر با $-844/9$ می‌باشد. در ستون بعدی، انحراف معیار تخمین‌زنده‌ها (Std. Error) ارائه شده است. همچنین از تقسیم مقدار هر ضریب بر انحراف معیار آن، مقدار آماره t به‌دست می‌آید که در ستون t-Statistic ارائه شده است. چون قدرمطلق t برای هر یک از ضرایب بیشتر از ۲ است لذا هر دو ضریب معنی‌دار هستند. در ستون آخر یعنی Prob. سطح معنی‌دار بودن ضرایب را نشان می‌دهد که اگر کمتر از ۰/۰۵ باشد بدین معنی است که ضرایب، لااقل در سطح ۰/۰۵ معنی‌دار هستند.

در قسمت پایین جدول، مقدار ضریب تعیین (R^2) با R-Squared و مقدار F نیز با F-Statistic مشخص شده‌اند. در این مثال $R^2 = 0/363$ و $F = 1/78$ می‌باشد. همچنین در زیر تابع F سطح معنی‌دار بودن F (یا معنی‌دار بودن معادله رگرسیون) ارائه شده است که در اینجا ۰/۰۱۷ می‌باشد. به‌طور کلی اگر این احتمال از ۰/۰۵ کمتر باشد، بدین معنی است که معادله رگرسیون معنادار است.

همچنین عبارت Mean dependent var بیانگر میانگین متغیر وابسته و S.D. dependent var نیز بیانگر انحراف معیار وابسته است. علاوه بر این، S.E. of regression نیز انحراف معیار معادله رگرسیون یعنی $\hat{\sigma}$ می‌باشد. مجموع مجذور خطاها یا RSS نیز با Sum squared resid نشان داده شده است. راجع به بقیه ارقامی که در جدول مذکور ارائه شده است در ادامه و به‌ویژه در فصل‌های بعدی بحث خواهد شد.

در پنجره Equation که نتایج معادله رگرسیون را نشان می‌دهد، منوهای مختلفی وجود دارد که هر کدام کارکردهای خاصی خود را دارند. به‌عنوان مثال در منوی View با انتخاب Actual, Fitted, Residual می‌توان نمودار و جدول مقادیر واقعی متغیر وابسته (Actual)، مقادیر برآوردی (Fitted) و باقیمانده‌ها (Residual) را به‌دست آورد. برای تابع سرمایه‌گذاری نمودار زیر به‌دست آمده است.



همچنین در منوی View گزینه‌های دیگری جهت انجام آزمون‌های مختلف وجود دارد که در قسمت‌های بعدی به آنها اشاره خواهد شد.

۱۴-۲ پیش‌بینی و فاصله اطمینان پیش‌بینی

پیش‌بینی یکی از ابزارهای مهم برای تصمیم‌گیرهای اقتصادی و مالی است و لذا یکی از مهمترین اهداف مدل‌های اقتصادسنجی می‌باشد. دقت این پیش‌بینی‌ها می‌تواند منجر به تصمیمات بهتر و دقیق‌تر شود و منافع آنها را بیشتر نماید.

پیش‌بینی‌ها را می‌توان بر اساس دوره زمانی، به دو دسته تقسیم نمود: پیش‌بینی درون‌نمونه‌ای و پیش‌بینی برون‌نمونه‌ای. پیش‌بینی درون‌نمونه‌ای مربوط به دوره‌ای است که مدل را برای همان دوره برآورد نموده‌ایم. به عنوان مثال اگر مدل برای دوره ۸۰-۱۳۵۰ برآورد شده باشد، در این صورت پیش‌بینی درون‌نمونه‌ای نیز برای دوره ۸۰-۱۳۵۰ انجام می‌شود. معمولاً نتایج پیش‌بینی درون‌نمونه‌ای نسبتاً خوب هستند. این نوع پیش‌بینی معمولاً برای بررسی دقت مدل می‌باشد، زیرا می‌توان مقادیر پیش‌بینی را با مقادیر واقعی مقایسه نمود.

پیش‌بینی برون‌نمونه‌ای، برای دوره بعد از برآورد مدل می‌باشد. مثلاً اگر دوره برآورد شامل ۸۰-۱۳۵۰ است، دوره بعد از آن می‌تواند شامل ۸۵-۱۳۸۱ یا ۹۵-۱۳۸۱ باشد. اگر در پیش‌بینی برون‌نمونه‌ای، دوره پیش‌بینی مربوط به گذشته باشد در این صورت امکان مقایسه مقادیر پیش‌بینی با مقادیر واقعی وجود دارد. ولی اگر مربوط به دوره آینده باشد امکان مقایسه وجود ندارد؛ زیرا مقادیر واقعی هنوز تحقق نیافته‌اند.

برای تعیین دقت پیش‌بینی، معیارهای مختلفی وجود دارد که در فصل یازدهم ارائه شده است. با استفاده از معادله رگرسیون می‌توان مقادیر Y را پیش‌بینی نمود. تخمین مقدار پیش‌بینی شده Y را با \hat{Y}_f نشان می‌دهیم. به عبارت دیگر اگر مقدار X در سال f برابر با X_f باشد آنگاه پیش‌بینی ما از Y برابر با \hat{Y}_f است:

$$\hat{Y}_f = \hat{\alpha} + \hat{\beta}X_f$$

اما مقدار دقیق Y در سال f برابر خواهد بود با:

$$Y_f = \hat{Y}_f + e_f$$

e_f مقدار خطای پیش‌بینی است. در اینجا نیز برای ساختن تخمین فاصله‌ای برای Y_f ، ابتدا امید ریاضی و واریانس خطای پیش‌بینی را محاسبه می‌کنیم:

$$e_f = Y_f - \hat{Y}_f \quad ; \quad Y_f = \alpha + \beta X_f + u_f \quad , \quad \hat{Y}_f = \hat{\alpha} + \hat{\beta} X_f \quad (2-28)$$

توجه شود که خطای واقعی پیش‌بینی برابر با u_f است که تخمین آن برابر با e_f می‌باشد.

$$\begin{aligned} \text{var}(e_f) &= \text{var}(Y_f - \hat{Y}_f) \\ &= \text{var}(Y_f) + \text{var}(\hat{Y}_f) - 2\text{cov}(Y_f, \hat{Y}_f) = \text{var}(Y_f) + \text{var}(\hat{Y}_f) \end{aligned} \quad (2-29)$$

Y_f و \hat{Y}_f مستقل از هم هستند، زیرا Y_f تابعی از u_f است اما \hat{Y}_f تابعی از $\hat{\alpha}$ و $\hat{\beta}$ بوده که این دو نیز تابعی از u_i هستند. چون طبق فرض «عدم خودهمبستگی» u_i و u_f مستقل از هم هستند؛ لذا باعث می‌شود که Y_f و \hat{Y}_f نیز مستقل از هم باشند و کوواریانس آنها صفر گردد:

$$\text{var}(e_f) = \text{var}(Y_f) + \text{var}(\hat{Y}_f) = \text{var}(u_f) + \text{var}(\hat{\alpha} + \hat{\beta} X_f)$$

زیرا طبق (2-28)، $\text{var}(Y_f) = \text{var}(u_f) = \sigma^2$ ، با محاسبه $\text{var}(\hat{\alpha} + \hat{\beta} X_f)$ خواهیم داشت:^۱

$$\text{var}(e_f) = \sigma^2 + \sigma^2 \left(\frac{1}{n} + \frac{(X_f - \bar{X})^2}{\sum x_i^2} \right) = \sigma^2 \left(1 + \frac{1}{n} + \frac{(X_f - \bar{X})^2}{\sum x_i^2} \right) \quad (2-30)$$

حال تابع t را تشکیل می‌دهیم:

$$t_{n-2} = \frac{e_f - E(e_f)}{\sqrt{\text{var}(e_f)}} = \frac{e_f - 0}{\sqrt{\text{var}(e_f)}} = \frac{Y_f - \hat{Y}_f}{\sqrt{\text{var}(e_f)}}$$

با استفاده از شرط $|t| \leq t_{\alpha/2, n-2}$ ، تخمین فاصله‌ای برای Y_f عبارت است از:

$$\begin{aligned} \left(\hat{Y}_f - t_{\alpha/2, n-2} \sqrt{\text{var}(e_f)} \leq Y_f \leq \hat{Y}_f + t_{\alpha/2, n-2} \sqrt{\text{var}(e_f)} \right) \\ \text{var}(e_f) = \sigma^2 \left(1 + \frac{1}{n} + \frac{(X_f - \bar{X})^2}{\sum x_i^2} \right) \end{aligned} \quad (2-31)$$

^۱ برای محاسبه واریانس $\hat{\alpha} + \hat{\beta} X_f$ ، ابتدا به جای $\hat{\alpha}$ قرار داده و سپس آن را به صورت زیر حساب می‌کنیم:

$$\begin{aligned} \text{var}(\hat{\alpha} + \hat{\beta} X_f) &= \text{var}(\bar{Y} - \hat{\beta} \bar{X} + \hat{\beta} X_f) = \text{var}[\bar{Y} + \hat{\beta}(X_f - \bar{X})] \\ &= \text{var}(\bar{Y}) + (X_f - \bar{X})^2 \text{var}(\hat{\beta}) = \frac{\sigma^2}{n} + \frac{(X_f - \bar{X})^2}{\sum (X_i - \bar{X})^2} \sigma^2 \end{aligned}$$

مثال ۱۳-۴: در مثال ۱۲-۲ اگر مقدار $X_f = 10$ باشد، مقدار پیش‌بینی شده Y_f را محاسبه کرده و تخمین فاصله را برای آن به دست آورید.

مقدار پیش‌بینی شده Y_f برابر با \hat{Y}_f است:

$$\hat{Y}_f = 3/266 + 1/38(10) = 17/066$$

و با توجه به محاسبات قبلی، تخمین فاصله‌ای به ازای $X_f = 8$ برابر است با:

$$17/066 \pm (2/1)(2/441) \sqrt{1 + \frac{1}{20} + \frac{(10 - 6/4)^2}{158/8}}$$


$$\Rightarrow 17/066 \pm 5/453 \Rightarrow (11/613, 22/519)$$

بدین ترتیب با احتمال ۹۵ درصد، مقدار Y_f در فاصله مذکور قرار خواهد داشت.


پیش‌بینی با Eviews

برای انجام پیش‌بینی با Eviews فرض کنید دوره زمانی شامل ۸۵-۱۳۵ باشد. ابتدا معادله مورد نظر را برای یک دوره دلخواه مانند ۸۰-۱۳۵، برآورد می‌کنیم. سپس در پنجره نتایج، با انتخاب Forecast → Proc پنجره زیر را باز می‌کنیم:

در قسمت Forecast name نامی را برای مقادیر پیش‌بینی شده متغیر وابسته انتخاب می‌کنیم. نرم‌افزار Eviews به آخر نام متغیر وابسته، حرف f را اضافه می‌کند (مانند Yf). همچنین در قسمت Forecast sample دوره پیش‌بینی را وارد می‌کنیم (مثلاً ۸۵-۱۳۵). با انتخاب OK مقادیر پیش‌بینی شده Y_f همراه با مرزهای آن (به اضافه و منهای دو انحراف معیار) ارائه می‌شود. در سمت راست آن اطلاعات دیگری نیز ارائه می‌شود که در فصل یازدهم در مورد آنها توضیح داده شده است.



همچنین می‌توان با فرمان $\text{plot } Y \text{ Yf}$ مقادیر واقعی و پیش‌بینی را در یک نمودار ترسیم کرده و مقایسه نمود. البته می‌توان برای دوره بعد از ۱۳۸۵، مثلاً تا ۱۳۹۰ نیز پیش‌بینی را انجام داد. در این حالت باید Range را تا ۱۳۹۰ گسترش دهیم. از طرف دیگر چون مقادیر X را برای سالهای ۱۳۸۶ تا ۱۳۹۰ نداریم، لذا بایستی مقادیر آن را به‌طور دلخواه یا در قالب سناریوهای مختلف تعیین کرده و سپس Y را تا ۱۳۹۰ پیش‌بینی نمود.



۲-۱۵ رگرسیون‌های غیرخطی


تاکنون معادله رگرسیون خطی را به صورت $Y_i = \alpha + \beta X_i + u_i$ در نظر گرفتیم. اما ممکن است رابطه X و Y غیرخطی باشد. در اینجا انواع خاصی از رگرسیون‌های غیرخطی را بررسی می‌کنیم که امکان تبدیل آنها به یک رابطه خطی وجود دارد تا امکان استفاده از روش OLS فراهم شود.

۲-۱۵-۱ روابط معکوس

روابط معکوس در مواردی وجود دارد که با افزایش X مقدار Y به سمت یک مقدار معین میل می‌کند. یکی از توابعی که می‌تواند چنین وضعیتی را نشان دهد عبارت است از:

$$Y_i = \alpha + \frac{\beta}{X_i} \quad (2-37)$$

نزولی یا صعودی بودن این رابطه، بستگی به علامت β دارد که نمودار زیر آن را نشان می‌دهد.



نمودار ۲-۷: روابط معکوس

برای برآورد این معادله می‌توان آن را به صورت خطی نوشت:

$$Y_i = \alpha + \beta X_i^*, \quad X_i^* = \frac{1}{X_i}$$

اثر تغییر X بر Y عبارت است از:

$$\frac{dY}{dX} = -\frac{\beta}{X^2}$$

اگر اثر تغییر X بر Y را بر حسب درصد بیان کنیم بیانگر کشش Y نسبت به X است که نشان می‌دهد یک درصد تغییر در X چند درصد Y را تغییر می‌دهد:

$$\eta = \frac{dy}{dx} \frac{X}{Y} = \left(-\frac{\beta}{X^2}\right) \frac{X}{Y} = -\frac{\beta}{XY}$$

برای محاسبه η معمولاً از میانگین‌های X و Y استفاده می‌شود.

$$\eta = -\frac{\beta}{XY}$$

برآورد روابط معکوس با Eviews

بدین منظور می‌توان معادله $Y_i = \alpha + \frac{\beta}{X_i}$ را با فرمان زیر برآورد کرد:

LS Y C 1/X

و یا می‌توان ابتدا با فرمان $genr z=1/x$ متغیر z را حساب کرده و سپس با فرمان LS Y C Z معادله را برآورد نمود.

۲-۱۵-۲ معادلات تمام لگاریتمی (log-log)

فرض کنید معادله رگرسیون به صورت زیر باشد:

$$Y_i = \alpha X_i^\beta e^{u_i} \quad (2-38)$$

با گرفتن لگاریتم از طرفین معادله فوق، خواهیم داشت:

$$\ln Y_i = \alpha + \beta \ln X_i + u_i, \quad \alpha = \ln a \quad (2-39)$$

معادله فوق شبیه یک معادله خطی است و لذا با روش OLS قابل برآورد است. اثر متغیر X بر Y به صورت زیر حساب می‌شود.


$$\eta = \frac{d \ln Y}{d \ln X} = \frac{dY/Y}{dX/X} = \frac{dY}{dX} \frac{X}{Y} = \beta$$

بنابراین β برابر با کشش Y نسبت به X است. برای محاسبه $\frac{dY}{dX}$ ، رابطه فوق را به صورت زیر می‌نویسیم:


$$\frac{dY}{dX} = \beta \frac{Y}{X}$$

در اینجا نیز برای محاسبه اثر X بر Y معمولاً از میانگین‌های X و Y استفاده می‌شود.

بدیهی است که معادله $Y = \alpha x^\beta$ کاملاً انعطاف پذیر است. به عنوان مثال اگر α و β مثبت باشند، نمودار زیر، رابطه X و Y را توصیف می کند.



اگر $\beta < 0$ باشد، خواهیم داشت:



برآورد معادله لگاریتمی با Eviews

بدین منظور فرمان زیر را اجرا می کنیم:

$$LS \ln(Y) C \ln(X)$$

که مقدار α یا $\ln \alpha$ و ضریب $\ln(X)$ نیز برابر با β است. بدیهی است که برای تعیین α از رابطه $\ln \alpha = \alpha$ یا $\alpha = e^\alpha$ استفاده می کنیم.

همچنین می توان ابتدا با فرمان `genr` متغیرهای $LY = \ln(Y)$ و $LX = \ln(X)$ را محاسبه کرده و سپس معادله رگرسیون لگاریتمی را با فرمان زیر برآورد نمود:

$$LS \ LY \ C \ LX$$

۲-۱۵-۳ توابع نمایی


اگر رابطه Y و X توسط یک تابع نمایی توصیف شود، شکل کلی آن به صورت زیر می باشد.

$$Y_i = ae^{\beta X_i + u_i} = ae^{\beta X_i} e^{u_i} \quad (2-40)$$


با گرفتن لگاریتم خواهیم داشت:

$$\ln Y_i = \alpha + \beta X_i + u_i, \quad \alpha = \ln a$$

معادله فوق را $\log\text{-lin}$ می گویند که به معنی لگاریتمی-خطی است، زیرا نسبت به Y لگاریتمی و نسبت به X خطی است.



نمودار ۲-۱۰: معادله لگاریتمی-خطی



نمودار ۲-۱۱: معادله لگاریتمی-خطی

اثر تغییرات X بر Y برابر است با:

$$\frac{d \ln Y}{dX} = \beta \Rightarrow \frac{dY/Y}{dX} = \beta \Rightarrow \frac{dY}{dX} = \beta Y$$

و کشش Y نسبت به X برابر است با:

$$\eta = \frac{dY}{dX} \frac{X}{Y} = \beta Y \frac{X}{Y} = \beta X$$

برآورد تابع نمای با Eviews

معادله log-lin را با فرمان زیر برآورد می‌کنیم:

$$LS \ln(Y) \ C \ X$$

C برآورد α و ضریب X برآورد β را نشان می‌دهند. برای محاسبه a از رابطه $\ln a = \alpha$ یا $a = e^\alpha$ استفاده می‌کنیم.

۴-۱۵-۲ رگرسیون انحراف از میانگین

معادله رگرسیون خطی به صورت زیر است:

$$Y_i = \alpha + \beta X_i + u_i \quad (2-41)$$

معادله فوق را جمع زده و بر n تقسیم می‌کنیم:

$$\frac{\sum Y_i}{n} = \frac{\sum (\alpha + \beta X_i + u_i)}{n}$$

$$\bar{Y} = \frac{n\alpha + \beta \sum X_i + \sum u_i}{n} \Rightarrow \bar{Y} = \alpha + \beta \bar{X} + \bar{u} \quad (2-42)$$

معادله (۲-۴۱) را منهای معادله (۲-۴۲) می‌کنیم:

$$Y_i - \bar{Y} = \beta(X_i - \bar{X}) + (u_i - \bar{u})$$

انحراف از میانگین را با $Y_i - \bar{Y} = y_i$ ، $X_i - \bar{X} = x_i$ و $u_i - \bar{u} = v_i$ نشان می‌دهیم:

$$y_i = \beta x_i + v_i \quad (2-43)$$

بنابراین، اگر داده‌ها را بر حسب انحراف از میانگین بنویسیم، عرض از مبدأ حذف می‌شود، ولی شیب معادله تغییری نمی‌کند. زیرا در رگرسیون $Y_i = \alpha + \beta X_i + u_i$ که تخمین آن به صورت

$\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$ است، خطای تخمین برابر است با:

$$e_i = Y_i - \hat{Y}_i = Y_i - \hat{\alpha} - \hat{\beta} X_i$$

$$= Y_i - (\bar{Y} - \hat{\beta} \bar{X}) - \hat{\beta} X_i ; \hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$

$$= (Y_i - \bar{Y}) - \hat{\beta} (X_i - \bar{X}) = y_i - \hat{\beta} x_i \quad (2-44)$$

بنابراین با حداقل نمودن مجموع مجذور خطاها، $\hat{\beta}$ به دست می‌آید:

$$\sum e_i^2 = \sum (y_i - \hat{\beta} x_i)^2$$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}} = 2 \sum (y_i - \hat{\beta} x_i)(-x_i) = 0 \Rightarrow \hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2} \quad (2-45)$$

بنابراین، تخمین شیب معادله رگرسیون، مشابه قبل است.

برآورد رگرسیون انحراف از میانگین با Eviews

رگرسیون انحراف از میانگین را فرمان زیر برآورد می‌کنیم:

$$LS \ Y - @mean(Y) \ X - @mean(X)$$

چون عرض از مبدأ این معادله برابر صفر است، لذا حرف C را ننوشته‌ایم. ضریب $X - @mean(X)$ برابر با تخمین β است.

۲-۱۵-۵ رگرسیون با متغیرهای استاندارد شده

مقادیر استاندارد شده X و Y عبارتند از:

$$X_i^* = \frac{X_i - \bar{X}}{S_x} = \frac{x_i}{S_x}, \quad Y_i^* = \frac{Y_i - \bar{Y}}{S_y} = \frac{y_i}{S_y} \quad (2-46)$$

توجه شود که $\sum X_i^* = \sum Y_i^* = 0$ است، زیرا

$$\sum X_i^* = \sum \frac{x_i}{S_x} = \frac{\sum x_i}{S_x} = 0$$

بنابراین $\bar{X}^* = \bar{Y}^* = 0$ خواهد بود.

معادله رگرسیون برای داده‌های استاندارد شده، عبارت است از:

$$Y_i^* = \alpha^* + \beta^* X_i^* \quad (2-47)$$

برای برآورد ضرایب، ابتدا $\sum e_i^{*2}$ را حساب کرده و سپس نسبت به $\hat{\alpha}^*$ و $\hat{\beta}^*$ مشتق می‌گیریم:

$$\begin{aligned} \sum e_i^{*2} &= \sum (Y_i^* - \hat{\alpha}^* - \hat{\beta}^* X_i^*)^2 \\ \frac{\partial \sum e_i^{*2}}{\partial \hat{\alpha}^*} &= 0 \Rightarrow \hat{\alpha}^* = \bar{Y}^* - \hat{\beta}^* \bar{X}^* = 0, \quad \hat{\beta}^* = \frac{\sum x_i^* y_i^*}{\sum x_i^{*2}} \\ \frac{\partial \sum e_i^{*2}}{\partial \hat{\beta}^*} &= 0 \end{aligned}$$

اگر به جای x^* و y^* قرار دهیم، خواهیم داشت:

$$\hat{\beta}^* = \frac{\sum x_i^* y_i^*}{\sum x_i^{*2}} = \frac{\sum \frac{x_i}{S_x} \frac{y_i}{S_y}}{\sum \frac{x_i^2}{S_x^2}} = \frac{S_x}{S_y} \frac{\sum x_i y_i}{\sum x_i^2} = \frac{S_x}{S_y} \beta$$


که β برابر با ضریب X در معادله $Y_i = \alpha + \beta X_i + u_i$ است. از طرف دیگر می‌توان $\hat{\beta}^*$ را با توجه

به $S_x^2 = \frac{\sum x_i^2}{n}$ به صورت زیر نوشت:

$$\hat{\beta}^* = \frac{S_x}{S_y} \frac{\sum x_i y_i}{n S_x^2} = \frac{\sum x_i y_i / n}{S_x S_y} = r_{xy} \quad (2-48)$$

بنابراین $\hat{\beta}^*$ برابر با ضریب همبستگی X و Y است و در نتیجه معادله رگرسیون را برای داده‌های استاندارد شده به صورت زیر می‌نویسیم:

$$\hat{Y}_i^* = \alpha^* + \hat{\beta}^* X_i^* = r_{xy} X_i^* ; \quad \alpha^* = 0, \quad \hat{\beta}^* = r_{xy}$$



نمودار ۲-۱۲: معادله رگرسیون با متغیرهای استاندارد شده

برآورد رگرسیون متغیرهای استاندارد شده با Eviews

رگرسیون متغیرهای استاندارد شده را می‌توان با فرمان زیر برآورد نمود:

$$LS \quad \frac{Y - @mean(Y)}{@std(Y)} \quad \frac{X - @mean(X)}{@std(X)}$$


که ضریب $\frac{X - @mean(X)}{@std(X)}$ برابر با ضریب همبستگی بین X و Y است.

۲-۱۵-۷ برآورد معادله روند

گاهی اوقات برخی از متغیرها دارای روند معینی در طول زمان هستند. اگر روند Y خطی باشد، یک معادله خطی را برای آن تعریف می‌کنیم:

$$Y_t = \alpha + \beta t + u_t$$

(۲-۴۹)




نمودار ۲-۱۳: خط روند

اگر روند غیرخطی باشد می توان از معادله زیر استفاده نمود.

$$Y_t = \alpha e^{\beta t} e^{u_t} \quad (2-50)$$

با گرفتن لگاریتم از طرفین خواهیم داشت:

$$\ln Y_t = \alpha + \beta t + u_t \quad (2-51)$$



نمودار ۲-۱۴: خط روند لگاریتمی

در معادله (۲-۵۱) شیب خط (β) برابر با نرخ رشد Y است.

برآورد معادله روند با Eviews

برای برآورد روند خطی، فرمان زیر را اجرا می کنیم:

LS Y C @trend

@trend بیانگر متغیر روند t می باشد که ضریب آن برابر با β است. برای برآورد معادله روند غیرخطی از فرمان زیر

استفاده می کنیم:

LS ln(Y) C @trend

۲-۱۵-۸ برآورد معادله نرخ رشد

برای برآورد معادله نرخ رشد، لازم است که تابع نمایی زیر را در نظر بگیریم.

$$Y_t = \alpha e^{\beta t} e^{u_t} \quad (2-52)$$

که لگاریتم آن عبارت است از:


$$\ln Y_t = \alpha + \beta t + u_t ; \alpha = \ln \alpha \quad (2-53)$$

با مشتق گیری نسبت به t ، نرخ رشد Y (که با \dot{Y} نشان می دهیم) به دست می آید.

$$\dot{Y} = \frac{d \ln Y}{dt} = \beta \quad (2-54)$$

زیرا $\frac{d \ln Y}{dt}$ برابر با $\frac{dY/t}{Y}$ است که معادل با نرخ رشد Y می باشد. بنابراین، ضریب t برابر با متوسط

نرخ رشد می باشد. شیب خط $\ln Y$ در مقابل t ، بیانگر متوسط نرخ رشد Y خواهد بود.



برآورد معادله رشد با Eview

پسین منظور فرمان زیر را اجرا می‌کنیم:

LS ln(Y) C @trend

ضریب @trend برابر با β ، یعنی متوسط نرخ رشد Y می‌باشد.

مثال ۱۴-۲: بر اساس مثال ۲-۲، معادله زیر را برآورد کنید:

$$Y_t = aX_t^\beta$$

ابتدا معادله فوق را به صورت لگاریتمی می‌نویسیم:

$$\log(Y_t) = \log(a) + \beta \log(X_t)$$

معادله فوق بر حسب لگاریتم متغیرها به صورت خطی است و لذا می‌توان آن را با روش

OLS برآورد نمود. نتایج برآورد به صورت زیر است:

$$\log(Y_t) = 1.435 + 0.574 \log(X_t) \quad R^2 = 0.756$$

$$(10/3) \quad (7/5) \quad F = 55/7$$

در این مثال $\beta = 0.574$ و $a = 10^{1.435} = 27.227$ می‌باشد. توجه شود که

چون $\beta = \frac{\partial \log(Y)}{\partial \log(X)}$ است، لذا β بیانگر درصد تغییر Y به ازای درصد تغییر X است که

معروف به کشش Y نسبت به X می‌باشد.

برآورد معادلات غیر خطی در Eviews

همان‌طور که اشاره شد برای برآورد معادلات غیر خطی در Eviews می‌توان ابتدا معادله را با تبدیل‌های مناسب، خطی نمود و سپس آن را مشابه معادلات خطی برآورد نمود. به عنوان مثال معادله $Y = ae^{\beta X}$ را ابتدا به صورت $\log(Y) = \alpha + \beta X$ نوشته که $\alpha = \log(a)$ است، و سپس با فرمان زیر آن را مانند یک معادله خطی برآورد می‌کنیم:

LS log(Y) C X

و یا می‌توان آن را با فرمان NLS (حداقل مربعات غیرخطی) به صورت زیر برآورد نمود:

$$\text{NLS } Y = C(1) * \exp(C(2) * X)$$

روش دیگر این است که از منوی Quick گزینه Estimate Equation را انتخاب کرده که به دنبال آن پنجره Equation Specification باز می‌شود. در این پنجره، معادله مورد نظر را یا به صورت خطی با فرمان $\log(Y) = C + X$ وارد می‌کنیم و یا به صورت غیرخطی یعنی $Y = C(1) * \exp(C(2) * X)$ وارد می‌کنیم و با انتخاب OK نتایج مربوطه به دست می‌آید.

۲-۱۶ تحلیل همبستگی

تحلیل همبستگی به بررسی رابطه بین دو یا چند متغیر می‌پردازد که معمولاً با کوواریانس یا ضریب همبستگی بیان می‌شود.

۲-۱۶-۱ کوواریانس

برای بیان همبستگی خطی بین دو متغیر X و Y ، یکی از معیارهای مهم و کاربردی، کوواریانس می‌باشد که به صورت زیر تعریف می‌گردد:

$$\text{cov}(X, Y) = \sigma_{xy} = E(X - \mu_x)(Y - \mu_y) = E(XY) - \mu_x \mu_y \quad (2-26)$$

μ_x و μ_y به ترتیب امید ریاضی X و Y هستند. کوواریانس X و Y را با $\text{cov}(X, Y)$ یا σ_{xy} و تخمین آن را بر حسب داده‌های نمونه با $\hat{\sigma}_{xy}$ نشان می‌دهیم که برابر است با:

$$\begin{aligned} \hat{\sigma}_{xy} &= \frac{\sum_{i=1}^n x_i y_i}{n} = \frac{\sum_{i=1}^n x_i Y_i}{n} = \frac{\sum_{i=1}^n X_i y_i}{n} \\ &= \frac{\sum X_i Y_i - \frac{(\sum X_i)(\sum Y_i)}{n}}{n} = \frac{\sum X_i Y_i}{n} - \bar{X} \bar{Y} \end{aligned}$$

مشکلی که در رابطه با کوواریانس وجود دارد این است که شدت و ضعف همبستگی خطی بین X و Y را بیان نمی‌کند. به عبارت دقیق‌تر مقدار آن کاملاً تحت تأثیر بزرگی و کوچکی مقادیر متغیرها قرار دارد. بدین منظور به مثال‌های ۲-۱۵ و ۲-۱۶ توجه کنید.

مثال ۱۵-۲: برای بررسی رابطه بین دو متغیر X و Y نمونه‌ای به حجم $n = 5$ انتخاب شد. که برای X مقادیر ۱، ۳، ۴، ۸ و برای Y نیز مقادیر ۲، ۴، ۶ و ۸ به دست آمده است. تخمین کوواریانس X و Y عبارت است از:

X_i	Y_i	$X_i Y_i$
۱	۲	۲
۳	۲	۶
۴	۴	۱۶
۸	۶	۴۸
۱۸	۲۰	۳۶۰

$$\bar{X} = \frac{18}{5} = 3.6, \quad \bar{Y} = \frac{20}{5} = 4$$

$$\text{cov}(X, Y) = \hat{\sigma}_{xy} = \frac{360}{5} - (3.6)(4) = 3.2$$

چون $\hat{\sigma}_{xy}$ مثبت است پس بین X و Y رابطه مثبت وجود دارد.

مثال ۱۶-۲: فرض کنید که مشاهدات X و Y در مثال ۱۵-۲ در ۱۰۰ ضرب شده باشند. کوواریانس X و Y را حساب کنید.

X_i	Y_i	$X_i Y_i$
۱۰۰	۲۰۰	۲۰۰۰۰
۳۰۰	۲۰۰	۶۰۰۰۰
۴۰۰	۴۰۰	۱۶۰۰۰۰
۸۰۰	۶۰۰	۴۸۰۰۰۰
۱۸۰۰	۲۰۰۰	۳۶۰۰۰۰۰

$$\bar{X} = \frac{1800}{5} = 360, \quad \bar{Y} = \frac{2000}{5} = 400$$

$$\hat{\sigma}_{xy} = \frac{360000}{5} - (360)(400) = 32000$$

در اینجا نیز چون کوواریانس مثبت است پس بین X و Y رابطه مثبت وجود دارد. در این مثال، کوواریانس X و Y نسبت به مثال قبلی ۱۰۰۰۰ برابر شده است که ناشی از بزرگ شدن مقیاس متغیرها است. اما پدیده‌ی که شدت همبستگی X و Y در هر دو حالت، یکسان است.

خواص کوواریانس

۱- اگر به X یا Y و یا به هر دو، مقدار ثابت a را اضافه یا کم کنیم، کوواریانس تغییری نمی‌کند.

$$\begin{aligned}\text{cov}(X+a, Y) &= \frac{\sum [(X_i + a) - (\bar{X} + a)](Y_i - \bar{Y})}{n} \\ &= \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{n} = \text{cov}(X, Y)\end{aligned}$$

و در حالت کلی خواهیم داشت:

$$\text{cov}(X \pm a, Y \pm b) = \text{cov}(X, Y)$$

۲- اگر مقدار X ها یا Y ها را در عدد ثابت a ضرب کنیم، کوواریانس نیز در a ضرب می‌شود.

$$\begin{aligned}\text{cov}(aX, Y) &= \frac{\sum (aX_i - a\bar{X})(Y_i - \bar{Y})}{n} \\ &= \frac{a \sum (X_i - \bar{X})(Y_i - \bar{Y})}{n} = a \text{cov}(X, Y)\end{aligned}$$

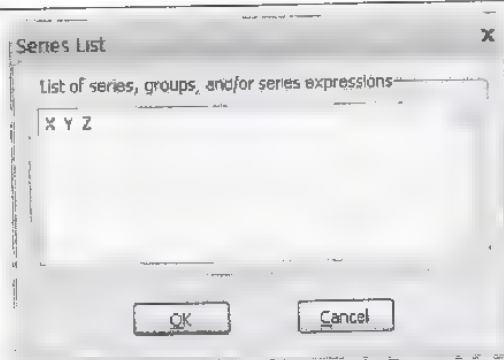
$$\begin{aligned}\text{cov}(X, aY) &= \frac{\sum (X_i - \bar{X})(aY_i - a\bar{Y})}{n} \\ &= \frac{a \sum (X_i - \bar{X})(Y_i - \bar{Y})}{n} = a \text{cov}(X, Y)\end{aligned}$$

۳- اگر X ها در a و Y ها در b ضرب شوند، کوواریانس در ab ضرب خواهد شد.

$$\begin{aligned}\text{cov}(aX, bY) &= \frac{\sum (aX_i - a\bar{X})(bY_i - b\bar{Y})}{n} \\ &= \frac{ab \sum (X_i - \bar{X})(Y_i - \bar{Y})}{n} = ab \text{cov}(X, Y)\end{aligned}$$

محاسبه کوواریانس با Eviews

برای محاسبه کوواریانس با Eviews می‌توان در سطر فرمان عبارت $\text{cov}(X, Y)$ را اجرا نمود. همچنین می‌توان از منوی Quick گزینه Group Statistics را انتخاب نمود که در این صورت پنجره Series List به صورت زیر باز می‌شود که نام متغیرهای مورد نظر را در آن وارد می‌کنیم:



نتایج محاسبه کوواریانس‌ها به صورت زیر نشان داده می‌شود:

Group: UNTITLED Workfile: INVESTMENT::Unt...									
View	Proc	Object	Print	Name	Freeze	Sample	Sheet	Stats	Spec
Covariance									
				X	Y	Z			
X				548006.3	28695.27	126031.3			
Y				28695.27	2058.391	7316.231			
Z				126031.3	7316.231	31871.92			

قطر اصلی، واریانس هر یک از متغیرها را نشان می‌دهد، به عنوان مثال واریانس X برابر با $۵۴۸۰۰۶/۳$ می‌باشد. سایر عناصر، کوواریانس بین متغیرها را نشان می‌دهد، مثلاً کوواریانس بین X و Y برابر با $۲۸۶۹۵/۲۷$ و کوواریانس بین X و Z برابر با $۱۲۶۰۳۱/۳$ و کوواریانس بین Y و Z برابر با $۷۳۱۶/۲۳۱$ می‌باشد.

۲-۱۶-۲ ضریب همبستگی

از مثال‌های ۲-۱۵ و ۲-۱۶ روشن است که کوواریانس کاملاً متأثر از مقدار متغیرها است. به عنوان نمونه، مثال ۲-۱۵ بیانگر اندازه‌گیری X و Y بر حسب متر است ولی در مثال ۲-۱۶ مقادیر X و Y بر حسب سانتی‌متر اندازه‌گیری شده است. بدیهی است که با تغییر مقیاس، شدت و ضعف همبستگی بین X و Y دچار تغییر نخواهد شد، در حالی که کوواریانس کوچک و بزرگ می‌شود.

برای حل این مشکل باید ابتدا متغیرهای X و Y را استاندارد نمود تا مقیاس اندازه‌گیری متغیرها تأثیر خود را از دست بدهد و سپس کوواریانس آنها را محاسبه کنیم:

$$Z_x = \frac{X - \mu_x}{\sigma_x}, \quad Z_y = \frac{Y - \mu_y}{\sigma_y}$$

σ_x و σ_y به ترتیب واریانس X و Y هستند. Z_x و Z_y استاندارد شده X و Y می‌باشند و از مقیاس متغیرهای X و Y متأثر نمی‌شوند. به عبارت دیگر اگر مقادیر X و Y بزرگ یا کوچک شوند، استاندارد شده آنها تغییر نمی‌کند. به عنوان مثال اگر X را دو برابر کنیم، میانگین و انحراف معیار X نیز دو برابر شده و لذا صورت و مخرج نیز دو برابر خواهند شد و Z_x ثابت می‌ماند. حال با توجه به اینکه امید ریاضی Z_x و Z_y برابر با صفر است کوواریانس Z_x و Z_y را که موسوم به ضریب همبستگی X و Y است به صورت زیر محاسبه می‌کنیم:

$$\begin{aligned} \text{cov}(Z_x, Z_y) &= \sigma_{Z_x, Z_y} = E(Z_x Z_y) = E\left(\frac{X - \mu_x}{\sigma_x}\right)\left(\frac{Y - \mu_y}{\sigma_y}\right) \\ &= \frac{E(X - \mu_x)(Y - \mu_y)}{\sigma_x \sigma_y} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} = \rho_{xy} \end{aligned} \quad (2-34)$$

تخمین ضریب همبستگی بر اساس داده‌های نمونه را با $\hat{\rho}_{xy}$ یا r_{xy} و یا به طور خلاصه با $\hat{\rho}$ یا r نشان می‌دهیم:

$$\begin{aligned} \hat{\rho} = r &= \frac{\hat{\sigma}_{xy}}{\hat{\sigma}_x \hat{\sigma}_y} = \frac{\hat{\sigma}_{xy}}{\sqrt{\hat{\sigma}_x^2 \hat{\sigma}_y^2}} = \frac{\frac{\sum x_i y_i}{n}}{\sqrt{\frac{\sum x_i^2}{n} \times \frac{\sum y_i^2}{n}}} \\ &= \frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{\sqrt{(\sum X_i^2 - n \bar{X}^2)(\sum Y_i^2 - n \bar{Y}^2)}} \end{aligned} \quad (2-35)$$

به سادگی می‌توان ثابت نمود که اگر X و Y در مقدار ثابتی مانند a ضرب یا تقسیم شوند مقدار r هیچ تغییری نخواهد کرد.

مثال ۱۷-۲: در مثال ۱۵-۲ و ۱۶-۲ ضریب همبستگی X و Y را محاسبه کنید.

X_i	Y_i	X_i^2	Y_i^2	$X_i Y_i$
۱	۲	۱	۴	۲
۳	۲	۹	۴	۶
۲	۴	۴	۱۶	۸
۴	۶	۱۶	۳۶	۲۴
۸	۶	۶۴	۳۶	۴۸
۱۸	۲۰	۹۴	۹۶	۸۸

$$\bar{X} = 3/6, \bar{Y} = 4, \sum X_i^2 = 94, \sum Y_i^2 = 96, \sum X_i Y_i = 88$$

$$r = \frac{88 - (5)(3/6)(4)}{\sqrt{(94 - 5 \times 3/6^2)(96 - 5 \times 4^2)}} = \frac{16}{\sqrt{(29/2)(16)}} = 0.74.$$

این محاسبات را اگر برای مثال ۱۶-۲ انجام دهیم، خواهیم داشت:

$$\bar{X} = 360, \bar{Y} = 400,$$

$$\sum X_i^2 = 940000, \sum Y_i^2 = 960000, \sum X_i Y_i = 880000$$

با قراردادن این مقادیر در فرمول r ، مقدار ضریب همبستگی همچنان برابر با ۰/۷۴ خواهد شد.

خواص ضریب همبستگی

۱- اگر به X ها یا Y ها و یا هر دو آنها مقدار ثابتی را اضافه یا کم کنیم، ضریب همبستگی تغییری نخواهد کرد.

$$r = \frac{\sum [(X_i + a) - (\bar{X} + a)][(Y_i + b) - (\bar{Y} + b)]}{\sqrt{\sum [(X_i + a) - (\bar{X} + a)]^2 \sum [(Y_i + b) - (\bar{Y} + b)]^2}}$$

$$= \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

۲- اگر X ها یا Y ها و یا هر دو را در عدد ثابتی ضرب یا تقسیم کنیم، ضریب همبستگی تغییری نخواهد کرد.


$$r_{ax,by} = \frac{\sum (aX_i - a\bar{X})(bY_i - b\bar{Y})}{\sqrt{\sum (aX_i - a\bar{X})^2 \sum (bY_i - b\bar{Y})^2}}$$

$$= \frac{ab \sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{a^2 \sum (X_i - \bar{X})^2 b^2 \sum (Y_i - \bar{Y})^2}}$$

$$= \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} = r$$

محاسبه ضرایب همبستگی با Eviews

برای محاسبه ضرایب همبستگی با Eviews می‌توان از منوی Quick گزینه Group Statistics و سپس Correlations را انتخاب که در این صورت پنجره Series List باز می‌شود.



پس از ورود نام متغیرهای مورد نظر و انتخاب OK، نتایج محاسبه ضرایب همبستگی به صورت زیر نشان داده می‌شود:

Group: UNTITLED Workfile: INVESTMENT:Untitled				
View	Proc	Object	Print	Name Freeze Sample Sheet Stats Spec
Correlation				
	X	Y	Z	
X	1.000000	0.856364	0.958390	
Y	0.856364	1.000000	0.908562	
Z	0.958390	0.908562	1.000000	

قطر اصلی برابر ۱ است زیرا ضرایب همبستگی هر متغیر با خودش برابر ۱ خواهد بود. سایر عناصر ضرایب همبستگی بین متغیرها را نشان می‌دهد، مثلاً ضرایب همبستگی بین X و Y برابر با ۰/۸۵۶ و ضرایب همبستگی بین X و Z برابر با ۰/۹۵۸ و ضرایب همبستگی بین Y و Z برابر با ۰/۹۰۶ می‌باشد.

آزمون فرضیه راجع به ضرایب همبستگی

ضرایب همبستگی خطی بین X و Y بیانگر شدت و ضعف رابطه خطی بین X و Y است. مقدار r بین +۱ و -۱ می‌باشد. هر چه r به صفر نزدیک باشد، رابطه خطی بین X و Y ضعیف است و هر چه که به +۱ و -۱ نزدیک باشد گفته می‌شود که X و Y رابطه قوی با هم دارند که در حالت اول رابطه قوی مثبت و در حالت دوم رابطه قوی دارند. اما سؤال این است r در چه محدوده‌ای باید باشد تا بگوییم که X و Y با هم رابطه‌ای ندارند. برای قضاوت در این مورد،

مجدداً به آزمون فرضیه متوسل می‌شویم. برای انجام آزمون $\rho = 0$ در مقابل $\rho \neq 0$ از آزمون t استفاده می‌شود:^۱

$$t_{n-2} = \sqrt{n-2} \frac{r}{\sqrt{1-r^2}} \quad (2-36)$$

اگر مقدار t از مقدار بحرانی (که معمولاً برابر با ۲ می‌باشد) بزرگتر باشد، فرضیه $\rho = 0$ رد می‌شود و ضریب همبستگی از نظر آماری معنادار است.

مثال ۲-۱۸: در مثال ۲-۲ ضریب همبستگی برابر با ۰/۸۵۹ می‌باشد. آیا ضریب همبستگی از نظر آماری معنادار است؟

$$t_{n-2} = \sqrt{20-2} \frac{0/859}{\sqrt{1-0/859^2}} = 7/118$$

چون مقدار $t = 7/118$ در ناحیه بحرانی قرار می‌گیرد، لذا فرضیه $\rho = 0$ رد می‌شود و ضریب همبستگی بین X و Y تفاوت معناداری از صفر دارد.

مثال ۲-۱۹: در مثال ۲-۱۷ ضریب همبستگی برابر با ۰/۷۴ می‌باشد. آیا ضریب همبستگی از نظر آماری معنادار است؟

$$t_{n-2} = \sqrt{5-2} \frac{0/74}{\sqrt{1-0/74^2}} = 1/91$$


چون مقدار $t = 1/91$ در ناحیه بحرانی قرار نمی‌گیرد (در اینجا عدد بحرانی برابر با $t_{1,0.05,3} = 3/182$ است)، لذا فرضیه $\rho = 0$ رد نمی‌شود و ضریب همبستگی بین X و Y تفاوت معناداری از صفر ندارد.

در مثال ۲-۱۹ علی‌رغم اینکه ضریب همبستگی برابر با ۰/۷۴ است، ولی به دلیل اندک بودن تعداد مشاهدات، تفاوت معناداری با صفر ندارد. این در حالی است که ضریب همبستگی ۰/۲ با ۲۰۰ مشاهده و یا ضریب همبستگی ۰/۴ با ۳۰۰ مشاهده، از نظر آماری معنادار است. توجه شود که اگر فقط دو مشاهده داشته

^۱ رابطه بین r و توزیع t با درجه آزادی $n-2$ دقیقاً معادل با توزیع t است که در آزمون معنادار بودن ضریب β به کار می‌رود. اگر در t به جای $\hat{\beta}$ و $\hat{\sigma}^2$ قرار داده و نتیجه را ساده کنیم خواهیم داشت:

$$t_{n-2} = \frac{\hat{\beta}}{\sqrt{\text{var}(\hat{\beta})}} = \sqrt{\sum x_i^2} \frac{\hat{\beta}}{\sqrt{\hat{\sigma}^2}} = \sqrt{n-2} \frac{r}{\sqrt{1-r^2}}$$

باشیم در این صورت ضریب همبستگی برابر با ۱ است و خط رگرسیون دقیقاً از این دو نقطه می‌گذرد، ولی از نظر آماری معنادار نیست.



نمودار ۱۶-۲: همبستگی خطی با دو مشاهده

مسائل

۱- با توجه به اطلاعات زیر مقادیر $\hat{\alpha}$ ، $\hat{\beta}$ و $SE(\hat{\beta})$ را حساب نمایید؟ آیا $\hat{\beta}$ از لحاظ آماری

معنادار است؟

$$n=40, \quad \bar{X}=420, \quad \bar{Y}=100, \quad \sum X_i Y_i = 850000 \\ \sum X_i^2 = 4000000, \quad RSS=140$$

۲- مدل‌های زیر مفروض هستند:

$$\ln Y_i = \beta_1 + \beta_2 \ln X_i + u_i \\ \ln Y_i^* = \alpha_1 + \alpha_2 \ln X_i^* + u_i^*$$

که $X_i^* = w_1 X_i$ و $Y_i^* = w_2 Y_i$ بوده w_1 و w_2 ثابت هستند. آیا R^2 در این دو مدل، متفاوت

است؟ ثابت کنید.

۳- در مسئله ۱ فصل اول، رگرسیون Y روی X را برآورد کرده و نتایج آن را تحلیل نمایید.

۴- در مسئله ۱ فصل اول، تغییرات Y را روی تغییرات X برازش کرده و نتایج آن را تحلیل و

با مسئله ۳ مقایسه نمایید.

۵- در مسئله ۱ فصل اول، ضریب همبستگی بین X ، Y و Z را حساب کرده و آزمون معنی دار بودن آنها را انجام دهید.

۶- در مسئله ۱ فصل اول، ضریب همبستگی بین نرخ رشد متغیرهای X ، Y و Z را حساب کرده و آزمون معنی دار بودن آنها را انجام دهید. نتایج را با مسئله ۵ مقایسه کنید.

۷- مقدار آماره t برای ضریب X در مسئله ۳ را با مقدار آماره t در آزمون معنی دار بودن ضریب همبستگی بین X و Y مقایسه کنید. دلیل تفاوت یا مشابهت چیست؟

۸- ثابت کنید که $\sum X_i e_i = 0$ است.

۹- ثابت کنید که $\sum \hat{Y}_i e_i = 0$ است.

۱۰- معادله رگرسیون برای $\bar{n} = 30$ مشاهده به صورت زیر برآورد شده است:

$$\hat{Y}_i = 2/5 + 4/2 X_i, \quad R^2 = 0/8$$

مقدار آماره t برای ضریب X_i و آماره F را حساب کنید.

۱۱- در مسئله ۱۰، فرضیه $\beta = 5$ را آزمون کنید.

۱۲- در معادله $Y_i = \alpha + \beta X_i + u_i$ مقادیر متغیرها بر حسب هزار ریال بیان شده است. اگر

مقادیر متغیرها را بر حسب ریال بیان کنیم آیا مقدار تخمینی ضرایب، تغییر خواهد کرد. چرا؟

۱۳- در مسئله ۳، رگرسیون Y روی X را برای دوره ۷۰-۱۳۵۱ برآورد کرده و سپس

مقادیر Y را برای دوره ۸۰-۱۳۷۱ پیش‌بینی کرده و با مقادیر واقعی مقایسه کنید.

۱۴- مفهوم فرض $E(u_i | X_i)$ را به طور مستدل توضیح دهید.

۱۵- مقادیر زیر را داریم:

$$\sum X_i = 130, \quad \sum Y_i = 240, \quad n = 20$$

$$\sum X_i^2 = 1000, \quad \sum Y_i^2 = 3500, \quad \sum X_i Y_i = 1800$$

معادله $Y_i = \alpha + \beta X_i + u_i$ را برآورد کرده و مقادیر t ، F و R^2 را حساب کنید.

۱۶- در مسئله ۱۵، ضریب همبستگی X و Y را حساب کرده و آزمون معنادار بودن آن را انجام

دهید.

۱۷- ثابت کنید که $\hat{\beta} \sim N(\beta, \frac{\sigma^2}{\sum x_i^2})$ است.


۱۸- ثابت کنید که $\sum y_i^2 = \sum \hat{y}_i^2 + \sum e_i^2$ است.

۱۹- در رگرسیون $Y_i = \alpha + \beta D_i + u_i$ متغیر D_i فقط مقادیر صفر و یک را اختیار می‌کند. مقدار D_i برای n_1 مشاهده برابر با ۱ و برای بقیه مشاهدات (n_2) برابر با صفر است ($n_1 + n_2 = n$). تخمین زننده α و β را به دست آورده و واریانس آنها را حساب کنید.

۲۰- در رگرسیون $Y_i = \alpha + \beta X_i + u_i$ امید ریاضی و واریانس شرطی را حساب کنید.

۲۱- ثابت کنید که اگر دو متغیر X و Y مستقل باشند، در آن صورت امید ریاضی شرطی Y مستقل از X خواهد بود.

۲۲- اگر مشاهدات X و Y به صورت نمودار زیر باشد، چه معادله‌ای را برای آن پیشنهاد می‌کنید.



۲۲- در معادله $Y_i = \alpha + \beta X_i + u_i$ کوواریانس $\hat{\alpha}$ و $\hat{\beta}$ را حساب کنید. آیا امکان دارد که $cov(\hat{\alpha}, \hat{\beta}) = 0$ باشد.

۲۳- ثابت کنید که $\sum \hat{y}_i^2 = \sum \hat{y}_i y_i$ است.

۲۴- ثابت کنید که $\sum \hat{y}_i e_i = 0$ است.

۲۵- ثابت کنید که معادله $\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$ از نقطه (\bar{X}, \bar{Y}) می‌گذرد. نمودار آن را ترسیم کنید.

۲۶- ثابت کنید که $\sum e_i = 0$ معادل $\bar{Y} = \hat{\alpha} + \hat{\beta} \bar{X}$ است.

۲۷- در معادله $Y_i = \alpha + \beta X_i + u_i$ اگر X_i و u_i مستقل نباشند، واریانس $\hat{\beta}$ را حساب کنید.

آیا با عبارت $\frac{\sigma^2}{\sum x_i^2}$ متفاوت خواهد بود یا نه؟

۲۸- فرض کنید که در معادله $Y_i = \alpha + \beta X_i + u_i$ ، متغیرهای u_i و X_i همبستگی مثبت داشته باشند. اگر $\beta > 0$ باشد، آنگاه ثابت کنید که تخمین β از روش OLS منجر به برآورد بیش از حد خواهد شد.

۲۹- اگر X_i و u_i در معادله $Y_i = \alpha + \beta X_i + u_i$ مستقل نباشند، آیا تخمین α از روش OLS دچار تورش خواهد شد؟

۳۰- ثابت کنید که در رگرسیون $Y_i = \alpha + \beta X_i + u_i$ ، تغییرات توضیح داده شده برابر است با:

$$ESS = \hat{\beta}^2 \sum x_i^2 = \hat{\beta} \sum x_i y_i$$

۳۱- اگر معادله $Y_i = a + ae^{\beta X_i}$ را داشته باشیم، اولاً نمودار آن را رسم کرده و ثانیاً چگونه آن را تبدیل به یک مدل قابل تخمین و خطی می‌کنید.

۳۲- اگر رگرسیون فقط دارای عرض از مبدأ باشد ($Y_i = \alpha + u_i$)، ثابت کنید که $\hat{\alpha} = \bar{Y}$ و

$$\text{var}(\hat{\alpha}) = \frac{\sigma^2}{n}$$

۳۳- رگرسیون‌های زیر را داریم:

$$1) Y_i = \alpha + \beta X_i + u_i$$

$$2) X_i = a + b Y_i + v_i$$

ضریب تعیین معادله (۱) و (۲) را به ترتیب با R_1^2 و R_2^2 نشان می‌دهیم.

الف) ثابت کنید که $R_1^2 = R_2^2$ است.

ب) ثابت کنید که $\hat{\beta} \leq \frac{1}{b}$ است.

ج) آیا تساوی $\sum \hat{u}_i^2 = \sum \hat{v}_i^2$ برقرار است؟

۳۴- رگرسیون‌های زیر برآورد شده‌اند:

$$Y_i = 2/45 + 1/25 X_i$$

$$X_i = 4.52 + 0.84 Y_i$$

آیا نتایج فوق درست است؟

۳۵- معادلات زیر برای درآمد و مصرف برآورد شده‌اند:

$$Y_i = \alpha + 1/25 C_i$$

$$C_i = a + 0.75 Y_i$$

الف) ضریب تعیین (R^2) را برای هر یک از این معادلات حساب کنید.

ب) آیا ضرایب تخمینی، معنادار هستند؟

ج) اگر $Y = C + S$ و S پس انداز باشد، ضریب همبستگی بین Y و S و بین S و C را حساب کنید.

۳۶- مقادیر Y_t روی زمان (t) برازش می شود که t از سال ۱۳۶۱ تا ۱۳۹۱ می باشد.

$$Y_t = \alpha + \beta t + u_t$$

ابتدا متغیر زمان را با مقادیر $t = 1, 2, \dots, 1390$ نشان داده و α و β را برآورد می کنیم که با $\hat{\alpha}$ و $\hat{\beta}$ نشان می دهیم. حال برای متغیر زمان مقادیر $t = 1, 2, \dots, 30$ را تعریف کرده و مجدداً معادله را برآورد کرده و با $\hat{\alpha}_t$ و $\hat{\beta}_t$ نشان می دهیم. چه تفاوتی بین $\hat{\alpha}_t$ با $\hat{\alpha}$ و همچنین $\hat{\beta}_t$ با $\hat{\beta}$ وجود دارد؟

۳۷- معادله $Y_t = aX_t^b$ را داریم. برای خطی کردن آن از طرفین لگاریتم می گیریم:

$$\log Y_t = \alpha + \beta X_t$$

$$\ln Y_t = \alpha + \beta X_t$$

آیا $\hat{\alpha}$ و $\hat{\beta}$ در این دو مدل متفاوتند؟

۳۸- در مدل $Y_t = aX_t^b$ متغیر تصادفی u_t توزیع نرمال با میانگین صفر و واریانس σ^2 دارد.

اگر برای برآورد این مدل از شکل لگاریتمی آن استفاده کنیم، خواهیم داشت:

$$\ln Y_t = \alpha + \beta X_t + \ln u_t, \quad \alpha = \ln a$$

الف) توزیع $\ln u_t$ چگونه خواهد بود؟

ب) اگر بخواهیم شرط $E(\ln u_t) = 0$ برقرار باشد، توزیع u_t چگونه خواهد بود؟

۳۹- رگرسیون $\hat{Y}_t = -2/5 + 0/8X_t$ با $n = 42$ مشاهد برآورد شده است. اگر $R^2 = 0/45$ باشد،

فرضیه های زیر را آزمون کنید:

$$H_1: \beta = 0 \quad \text{الف)}$$

$$H_1: R^2 = 0 \quad \text{ب)}$$

۴۰- در مسئله ۱۳۹ اگر $n = 10$ باشد فرضیه های مورد نظر را آزمون کنید. نتیجه آزمون چه

تفاوتی کرد؟ چرا؟

۴۱- در رگرسیون $Y_t = \alpha + \beta X_t + u_t$ وقتی از روش OLS استفاده می شود، ثابت کنید که

روابط زیر برقرار است:

$$\sum e_i = 0 \text{ (الف)}$$

$$\sum e_i X_i = 0 \text{ (ب)}$$

$$\sum e_i \hat{Y}_i = 0 \text{ (ج)}$$

$$\sum Y_i = \sum \hat{Y}_i \text{ (د)}$$

۴۲- نشان دهید که در رگرسیون $Y_i = \alpha + \beta X_i + u_i$ شرط $\bar{Y} = \bar{\hat{Y}}$ برقرار است ولی در

رگرسیون $Y_i = \beta X_i + u_i$ ، برقرار نیست. عدم برقراری این شرط به چه معنا است؟

۴۳- ثابت کنید که R^2 برابر با ضریب همبستگی \hat{Y}_i و Y_i است.

ضمیمه فصل ۲: رگرسیون ساده در Stata

برآورد رگرسیون ساده با Stata

فایل data1

به منظور برآورد رگرسیون خطی، مسیر زیر را دنبال می‌کنیم:

Linear regression → Linear models and related → Statistics

استاتاستیک معادله را با عرض از مبدأ برآورد می‌کند.
اگر عرض از مبدأ نمی‌خواهید اینجا را کلیک کنید

علاوه بر این، می‌توان معادله را با فرمان زیر تخمین زد:

```
reg y x
```

اگر بخواهیم Y را فقط روی عرض از مبدأ رگرس کنیم، از فرمان زیر استفاده می‌کنیم:

```
reg y
```

و برای رگرسیون بدون عرض از مبدأ، فرمان زیر را اجرا می‌کنیم:

```
reg y x, noc
```

بعد از اجرای هر یک از فرمان‌های فوق، نتایج تخمین عبارت است از:

دگرسیون π روی ip regress π ip rr

مجموع مجذور تغییرات درجه آزادی میانگین تغییرات

Source	SS	df	MS
Model	798106043	1	798106043
Residual	2.2374e+09	19	117756217
Total	3.0355e+09	20	151773708

ESS
RSS
TSS

ضرب π

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ip	-844.9209	324.5471	-2.60	0.017	-1524.206 -165.6361
rr	201.31.31	2587.601	7.78	0.000	14715.4 25547.22
cons					

عرض از مبدأ تخمین ضرایب

نسبت t انحراف معیار ضرایب

سطح معنی داری ضرایب

فاصله اطمینان ۹۵ درصدی برای ضرایب

تعداد مشاهدات F F معنی داری R^2 R^2 σ^2

Number of obs = 21
F(1, 19) = 6.78
Prob > F = 0.0175
R-squared = 0.2629
Adj R-squared = 0.2241
Root MSE = 10852

محاسبه مقادیر برآوردی و باقیمانده‌ها

برای محاسبه مقادیر برآوردی \hat{Y} یعنی \hat{y} ، بعد از برآورد مدل مورد نظر، فرمان زیر را اجرا می‌کنیم:

predict yhat

برای محاسبه باقیمانده‌ها (خطاها) نیز فرمان زیر را اجرا می‌کنیم:

predict e, residuals

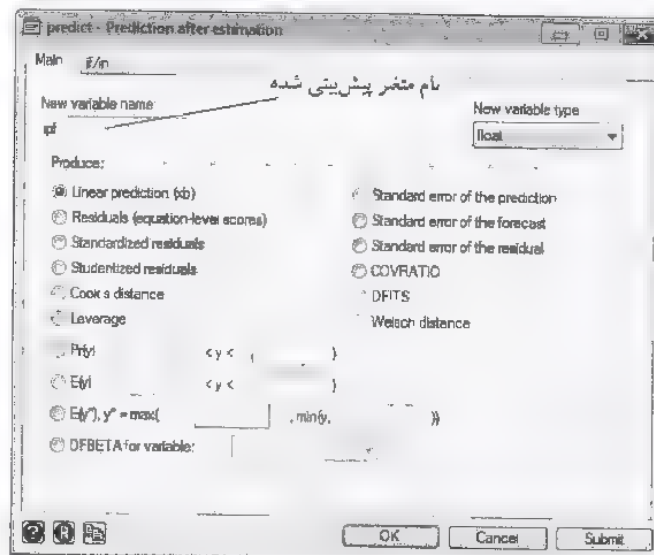
به جای روش فوق می‌توان به روشی که در قسمت بعدی، برای پیش‌بینی گفته می‌شود، عمل نمود.

پیش‌بینی با Stata

پیش‌بینی به دو صورت است: درون نمونه‌ای و بیرون نمونه‌ای. پیش‌بینی درون نمونه‌ای مشابه برآورد مقادیر تخمینی است که در بالا به آن اشاره شد. این نوع پیش‌بینی را به صورت زیر نیز می‌توان انجام داد. بدین منظور، بعد از تخمین مدل، مسیر زیر را دنبال می‌کنیم:

Predictions, Residuals, etc → Postestimation → Statistics

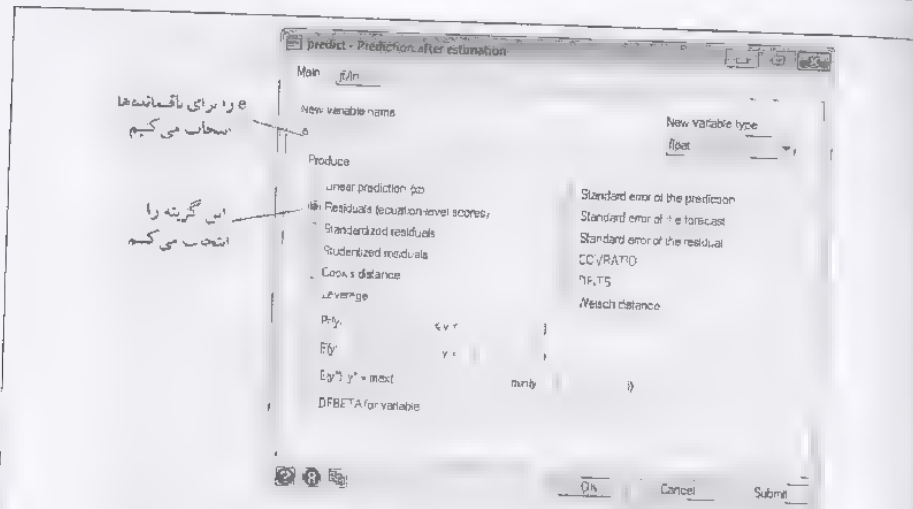
با انتخاب مسیر فوق پنجره زیر باز می‌شود که گزینه‌های مربوط به آن عبارتند از:



با انجام مراحل فوق، مقادیر پیش‌بینی شده \hat{y} با نام ipf محاسبه می‌شود. برای مقایسه آنها می‌توان با فرمان زیر نمودار مربوطه را ترسیم نمود.

twoway (line ip ipf t)

همچنین برای محاسبه باقیمانده‌ها (خطاهای پیش‌بینی)، مشابه محاسبه مقادیر پیش‌بینی عمل کرده و در پنجره مربوط به پیش‌بینی، به صورت زیر عمل می‌کنیم:

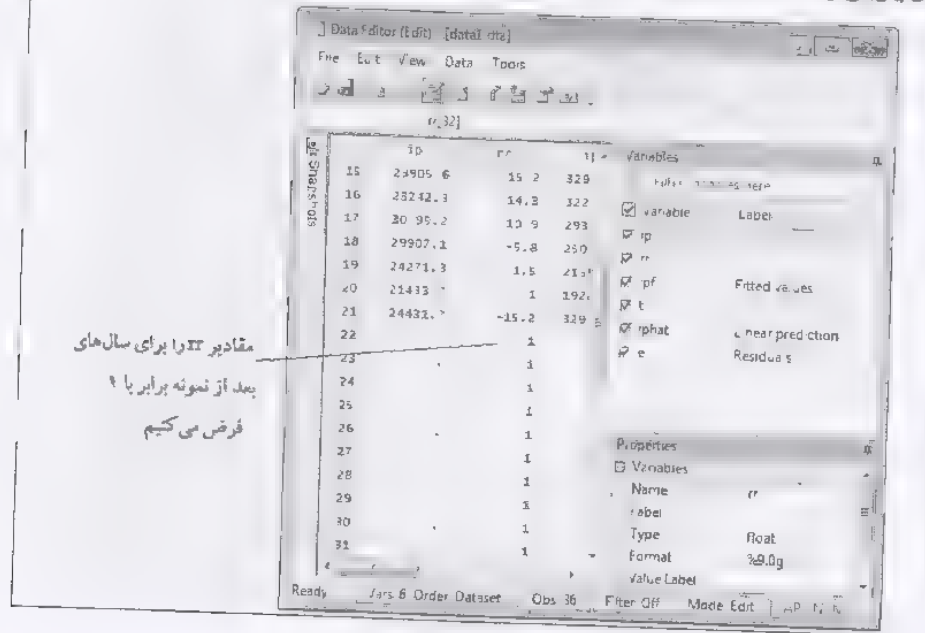


در قسمت variables نام

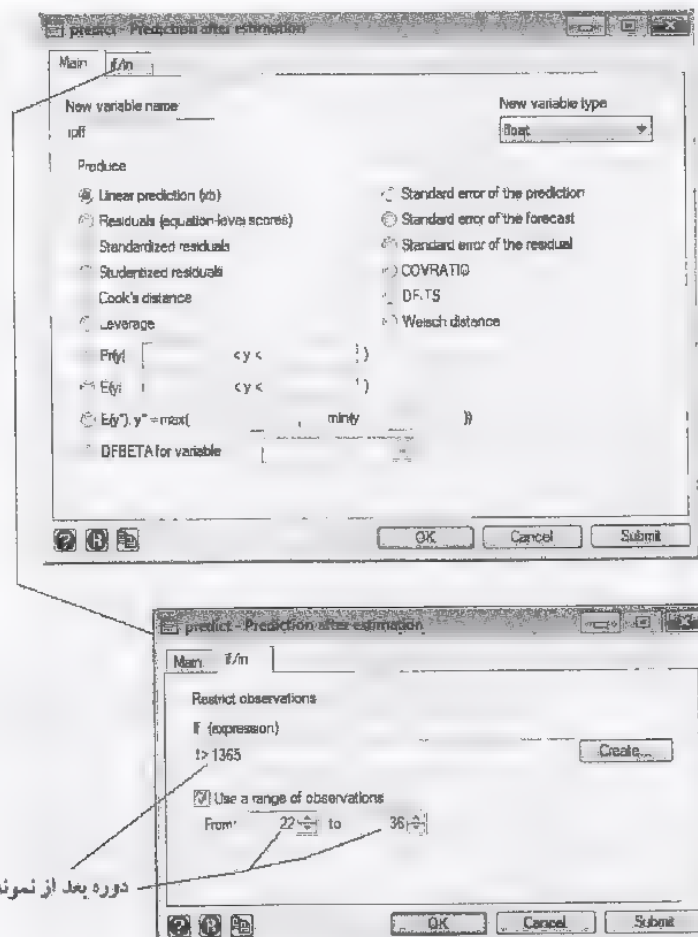
متغیر e اضافه می شود

Name	Label	Type	Format
date		int	%8.0g
p		float	%9.0g
r		float	%9.0g
pf	Linear prediction	float	%9.0g
e	Residuals	float	%9.0g

برای پیش بینی برون نمونه ای، ابتدا مقادیر متغیر توصیفی (در اینجا IT) را برای دوره بعد از نمونه، اضافه می کنیم:



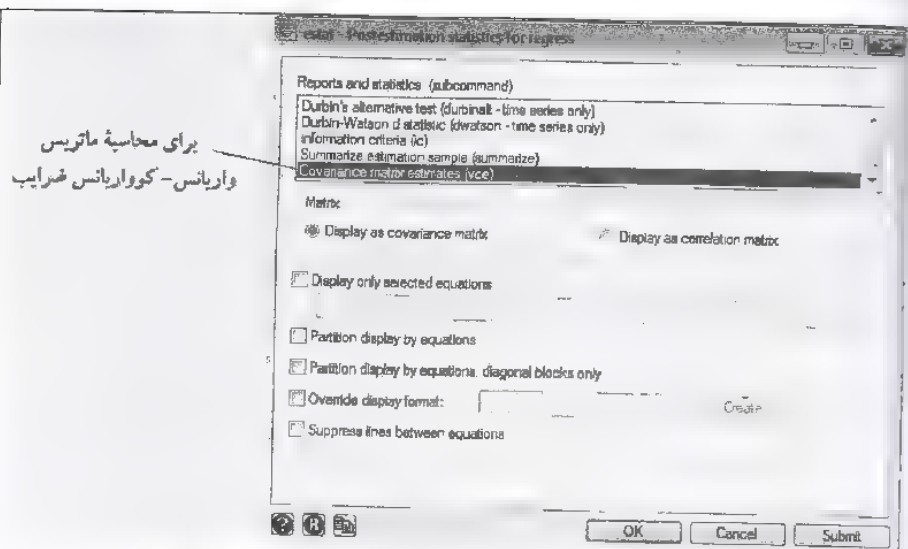
حال پنجره predict را باز کرده و نام متغیر موردنظر را (در اینجا ipff) وارد می‌کنیم. سپس متغیر if/in را انتخاب کرده و دوره پیش‌بینی برون نمونه‌ای را وارد می‌کنیم.



با انتخاب OK نتایج پیش‌بینی برون نمونه‌ای به‌دست می‌آید که می‌توان مقادیر آن را مشاهده و ترسیم نمود. برای رسم آن می‌توان از فرمان `tsline ip ipff if t>1365` استفاده نمود.

محاسبه ماتریس واریانس-کوواریانس ضرایب
بدین منظور مسیر زیر را دنبال می‌کنیم:

Report and Statistics → Postestimation → Statistics



نتایج عبارتند از:

Results

estat vce

Covariance matrix of coefficients of regress model

e(V)	rr	_cons
rr	105330.8	
_cons	338563.27	6695678

کوواریانس ضرایب

واریانس عرض از مبدأ

واریانس ضریب π

بر آورد معادلات غیر خطی با Stata

در سطر فرمان معادله مورد نظر را وارد می کنیم. مثال های زیر نحوه تخمین معادلات غیر خطی را نشان می دهند:

$$Y = \alpha + \beta X \Rightarrow \text{nl } (y = \{b0\} + \{b1\} * x)$$

$$Y = \alpha + \frac{\beta}{X} \Rightarrow \text{nl } (y = \{b0\} + \{b1\} / x)$$

$$Y = \alpha + \beta X^2 \Rightarrow \text{nl } (y = \{b0\} + \{b1\} * x^2)$$


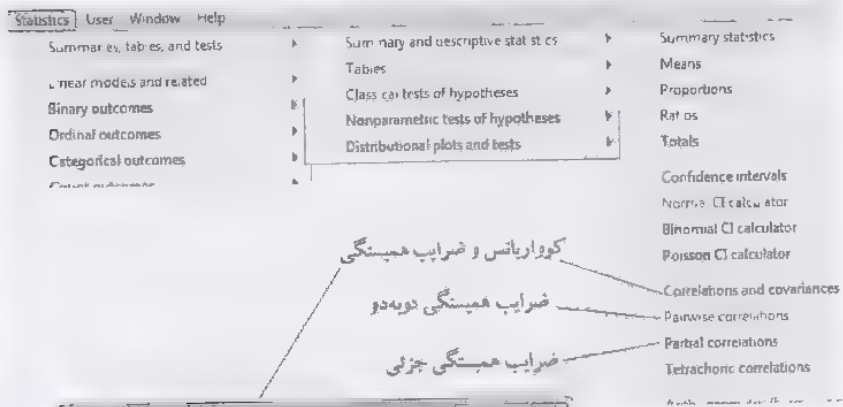
$$Y = \alpha X^\beta \Rightarrow \text{nl } (y = \{b0\} * x^{\{b1\}})$$

$$Y = \alpha + \beta X^\theta \Rightarrow \text{nl } (y = \{b0\} + \{b1\} * x^{\{b3\}})$$

محاسبه ضرایب همبستگی

برای محاسبه ضرایب همبستگی، مسیر زیر را دنبال می‌کنیم:

summary and description statistics → Summaries, Tables, and test → Statistics



نتایج عبارتند از:

	ip	rr
ip	1.0000	
rr	0.5128	1.0000

تجاذب نکردن برخی از مشاهدات

اگر بخواهیم در تخمین معادلات و یا در سایر محاسبات، شرطی را قایل شویم می‌توان آن را با if تعارض نمود. به عنوان مثال می‌خواهیم آن بخش از مشاهدات که y برابر صفر است، در نظر گرفته نشوند. بدین منظور از فرمان زیر استفاده می‌کنیم:

Drop if $y=0$

این فرمان موجب حذف آن بخش از مشاهدات می‌شود که $y=0$ است. همچنین می‌توان به جای صفر هر عدد دیگری را نیز در نظر گرفت. به جای مساوی می‌توان از کوچکتر و بزرگتر نیز استفاده نمود.

علاوه بر این، می‌توان روی معادله رگرسیون شرط گذاشت. مثلاً می‌خواهیم معادله را به ازای داده‌هایی تخمین بزنیم که $Z>0$ باشد. Z هر متغیری می‌تواند باشد، اهم از اینکه متغیر توضیحی، وابسته و یا حتی در معادله موجود نباشد.

`reg y x if z>=0`

رگرسیون چندمتغیره

۳-۱ مقدمه

در فصل دوم، رگرسیون ساده و مفاهیم اصلی آن تشریح گردید. در این فصل رگرسیون چندمتغیره را بررسی می‌کنیم که در حالت کلی شامل K متغیر توضیحی است. برای سادگی بحث، ابتدا حالت دو متغیره و سپس حالت کلی را بررسی خواهیم کرد.

۳-۲ رگرسیون دو متغیره: مفاهیم و فروض

در اینجا برای سادگی، بحث را با رگرسیون دو متغیره یعنی رگرسیونی که دارای دو متغیر توضیحی است، شروع می‌کنیم. بدین منظور معادله زیر را در نظر بگیرید:

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + u_i \quad (3-1)$$

که در آن $\alpha + \beta_1 X_{1i} + \beta_2 X_{2i}$ جزء غیرتصادفی یا معین و u_i جزء تصادفی یا اخلال می‌باشد.

در مورد u_i تمام فروض رگرسیون یک متغیره برقرار است و لذا برای Y_i داریم:

$$E(Y | X_1, X_2) = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} \quad (3-2)$$

$$\text{var}(Y | X_1, X_2) = \text{var}(u_i | X_1, X_2) = \sigma^2 \quad (3-3)$$

یکی از مشکلات مدل‌های چندمتغیره، مسئله همخطی بین متغیرهای توضیحی X_1 و X_2 است.

همخطی یا وابستگی خطی بین این دو متغیر را می‌توان به صورت زیر بیان نمود:

$$\lambda_1 X_{1i} + \lambda_2 X_{2i} = 0 \quad (3-4)$$

اگر هیچ همخطی وجود نداشته باشد، آنگاه $\lambda_1 = \lambda_2 = 0$ است. ولی اگر همخطی، کامل باشد در این صورت λ_1 و λ_2 صفر نخواهند بود و لذا می توان (۳-۴) را به صورت زیر نوشت:

$$X_{1i} = -\frac{\lambda_2}{\lambda_1} X_{2i} \Rightarrow X_{2i} = a X_{1i} \quad ; \quad a = -\frac{\lambda_2}{\lambda_1} \quad (3-5)$$

حال اگر (۳-۵) را در (۳-۱) قرار دهیم، خواهیم داشت:

$$\begin{aligned} Y_i &= \alpha + \beta_1 X_{1i} + \beta_2 (a X_{1i}) + u_i \\ &= \alpha + (\beta_1 + \beta_2 a) X_{1i} + u_i \\ &= \alpha + \beta X_{1i} + u_i \quad ; \quad \beta = \beta_1 + \beta_2 a \end{aligned} \quad (3-6)$$

بنابراین در صورت همخطی کامل، نمی توان ضرایب مدل (۳-۱) را برآورد نمود، بلکه فقط دو ضرایب α و β برآورد می شوند و امکان برآورد β_1 و β_2 وجود ندارد.

۳-۳ تخمین ضرایب رگرسیون دو متغیره و خواص آنها

برای تخمین ضرایب مدل رگرسیون دو متغیره، مانند رگرسیون یک متغیره، مقدار واقعی را با Y_i و مقدار تخمینی را با \hat{Y}_i نشان می دهیم. لذا خطای تخمین عبارت است از:

$$e_i = Y_i - \hat{Y}_i = Y_i - (\hat{\alpha} + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i})$$

و مجموع مجذور خطاها عبارت است از:

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i})^2 \quad (3-7)$$

ضرایب $\hat{\alpha}$ ، $\hat{\beta}_1$ و $\hat{\beta}_2$ باید به گونه ای تعیین شوند که مجموع مجذور خطا، حداقل شود:

$$\begin{aligned} \frac{\partial \sum e_i^2}{\partial \hat{\alpha}} &= -2 \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i}) = 0 \quad \text{یا} \quad \sum e_i = 0 \\ \frac{\partial \sum e_i^2}{\partial \hat{\beta}_1} &= -2 \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i}) X_{1i} = 0 \quad \text{یا} \quad \sum e_i X_{1i} = 0 \\ \frac{\partial \sum e_i^2}{\partial \hat{\beta}_2} &= -2 \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i}) X_{2i} = 0 \quad \text{یا} \quad \sum e_i X_{2i} = 0 \end{aligned} \quad (3-8)$$

معادله اول را به صورت $\sum Y_i = n\hat{\alpha} + \hat{\beta}_1 \sum X_{1i} + \hat{\beta}_2 \sum X_{2i}$ نوشته و با تقسیم طرفین آن بر n رابطه $\hat{\alpha} = \bar{Y} - \hat{\beta}_1 \bar{X}_1 - \hat{\beta}_2 \bar{X}_2$ را به دست می آوریم. اگر در معادلات دوم و سوم به جای $\hat{\alpha}$ قرار داده و آنها را بر حسب انحراف از میانگین بنویسیم، خواهیم داشت:

$$\sum_{i=1}^n (y_i - \hat{\beta}_1 x_{1i} - \hat{\beta}_2 x_{2i}) x_{1i} = 0$$

$$\sum_{i=1}^n (y_i - \hat{\beta}_1 x_{1i} - \hat{\beta}_2 x_{2i}) x_{2i} = 0$$

با ساده نمودن دو معادله فوق، خواهیم داشت:

$$\sum x_{1i} y_i - \hat{\beta}_1 \sum x_{1i}^2 - \hat{\beta}_2 \sum x_{1i} x_{2i} = 0 \quad (3-9)$$

$$\sum x_{2i} y_i - \hat{\beta}_1 \sum x_{1i} x_{2i} - \hat{\beta}_2 \sum x_{2i}^2 = 0 \quad (3-10)$$

که شکل ماتریسی آن عبارت است از:

$$\begin{bmatrix} \sum x_{1i}^2 & \sum x_{1i} x_{2i} \\ \sum x_{1i} x_{2i} & \sum x_{2i}^2 \end{bmatrix} \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} \sum x_{1i} y_i \\ \sum x_{2i} y_i \end{bmatrix} \quad (3-11)$$

با حل معادلات فوق، $\hat{\beta}_1$ و $\hat{\beta}_2$ به دست می آید.

مثال ۳-۱ داده‌های مربوط به سه متغیر X_1 ، X_2 و Y در جدول زیر ارائه شده است:

Y	X_1	X_2
۱۰	۲	۱۰۰
۱۲	۲	۱۰۰
۱۲	۴	۱۱۰
۱۴	۵	۱۲۰
۱۴	۵	۱۲۰
۱۵	۴	۱۴۰
۱۴	۶	۱۵۰
۱۶	۶	۱۵۰
۱۸	۸	۱۲۰
۲۰	۱۰	۱۵۰
۲۰	۱۰	۱۶۰
۲۲	۸	۱۶۰
۲۲	۱۰	۱۸۰
۲۴	۱۲	۲۰۰
۲۵	۱۲	۲۲۰
۲۵	۱۲	۲۲۰
۲۸	۱۴	۲۲۰
۲۹	۱۶	۲۴۰
۳۰	۱۶	۲۵۰
۳۰	۱۸	۲۵۰
۴۰۰	۱۸۰	۳۳۶۰

از جدول فوق $\bar{X}_1 = 168$ ، $\bar{X}_2 = 168$ و $\bar{Y} = 20$ به دست می آید. نتایج حاصل از بقیه محاسبات به صورت زیر است:

$$\begin{aligned} \sum x_{1i}^2 &= 434 & , & & \sum x_{2i}^2 &= 49320 \\ \sum y_i^2 &= 800 & , & & \sum x_{1i} x_{2i} &= 4400 \\ \sum x_{1i} y_i &= 576 & , & & \sum x_{2i} y_i &= 6040 \end{aligned}$$

تخمین ضرایب عبارت است از:

$$\begin{bmatrix} 434 & 4400 \\ 4400 & 49320 \end{bmatrix} \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} 576 \\ 6040 \end{bmatrix} \Rightarrow \hat{\beta}_1 = 0.189605, \hat{\beta}_2 = 0.12253$$

$$\hat{\alpha} = \bar{Y} - \hat{\beta}_1 \bar{X}_1 - \hat{\beta}_2 \bar{X}_2 = 20 - (0.189605)(9) - (0.12253)(168) = -13.2095$$

بنابراین معادله رگرسیون عبارت است از:

$$\hat{Y}_i = -13.2095 + 0.189605 X_{1i} + 0.12253 X_{2i}$$

از آنجا که $\hat{\beta}_1$ و $\hat{\beta}_2$ تابعی از Y و به تبع آن تابعی از u می باشند لذا دارای توزیع نرمال با امید ریاضی β_1 و β_2 هستند.^۱ از طرف دیگر، واریانس $\hat{\beta}_1$ و $\hat{\beta}_2$ ، علاوه بر σ^2 به ضرایب همبستگی

۱- برای اثبات این قضایا لازم است که $\hat{\beta}_1$ را به صورت زیر بنویسیم:

$$\hat{\beta}_1 = \sum_{i=1}^n w_i y_i, \quad w_i = \frac{\sum x_{2i} x_{1i} - x_{2i} \sum x_{1i} x_{2i}}{\sum x_{1i} \sum x_{2i} - (\sum x_{1i} x_{2i})^2}$$

بدین ترتیب $\hat{\beta}_1$ ترکیب خطی از Y_i است که اگر به جای Y_i قرار دهیم، خواهیم داشت:

$$\hat{\beta}_1 = \sum w_i Y_i = \sum w_i (\alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + u_i) = \beta_1 + \sum w_i u_i$$

بنابراین می توان به سادگی نتیجه گرفت که $E(\hat{\beta}_1) = \beta_1$ است. برای محاسبه واریانس $\hat{\beta}_1$ نیز به صورت زیر عمل می کنیم:

$$\text{var}(\hat{\beta}_1) = E(\hat{\beta}_1 - \beta_1) = E(\sum w_i u_i) = E(\sum w_i^2 u_i^2)$$

زیرا $E(u_i u_j) = 0$ است.

$$\text{var}(\hat{\beta}_1) = \sum w_i^2 E(u_i^2) = \sum w_i^2 \sigma^2 = \sigma^2 \sum w_i^2$$

با محاسبه $\sum w_i^2$ خواهیم داشت:

$$\text{var}(\hat{\beta}_1) = \sigma^2 \sum w_i^2 = \sigma^2 \frac{\sum x_{2i}^2}{\sum x_{1i}^2 \sum x_{2i}^2 - (\sum x_{1i} x_{2i})^2} = \frac{\sigma^2}{(1 - r_{12}^2) \sum x_{1i}^2}$$

بین X_1 و X_2 نیز بستگی دارد. هر چه ضریب همبستگی X_1 و X_2 بیشتر باشد، واریانس‌ها نیز بزرگتر می‌شود و همچنان که در آزمون فرضیه معنی‌دار بودن ضرایب رگرسیون خواهیم دید، ضرایب بی‌معنی خواهند شد. در صورت همبستگی کامل بین X_1 و X_2 ضریب همبستگی آنها برابر با ۱ است ($r_{12}^2 = 1$) و در این حالت واریانس‌ها بی‌نهایت خواهند شد. اما اگر $r_{12}^2 = 0$ باشد در این صورت واریانس $\hat{\beta}_1$ مشابه واریانس آن در معادله رگرسیون Y روی X_1 می‌باشد. همین بحث را برای X_2 نیز می‌توان مطرح نمود.

$$\hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{(1-r_{12}^2)\sum x_{1i}^2}\right) \quad (3-12)$$

$$\hat{\beta}_2 \sim N\left(\beta_2, \frac{\sigma^2}{(1-r_{12}^2)\sum x_{2i}^2}\right)$$

$$\hat{\alpha} \sim N\left(\alpha, \sigma^2 \left[\frac{1}{n} + \frac{(\bar{X}_1)^2 \sum x_{1i}^2 + (\bar{X}_2)^2 \sum x_{2i}^2 - 2\bar{X}_1\bar{X}_2 \sum x_{1i}x_{2i}}{(1-r_{12}^2)\sum x_{1i}^2 \sum x_{2i}^2} \right] \right)$$

$$r_{12}^2 = X_2 \text{ و } X_1 \text{ مجذور ضریب همبستگی} = \frac{(\sum x_{1i}x_{2i})^2}{\sum x_{1i}^2 \sum x_{2i}^2}$$

۳-۴ ضریب تعیین و خطای معادله رگرسیون

برآورد واریانس u که با $\hat{\sigma}^2$ نشان داده می‌شود، واریانس معادله رگرسیون می‌باشد که مشابه رگرسیون یک متغیره می‌توان آن را محاسبه نمود. انحراف معیار ($\hat{\sigma}$) نشان می‌دهد که به‌طور متوسط، مقادیر واقعی Y چقدر از مقادیر تخمینی انحراف دارند. طبق تعریف، واریانس معادله رگرسیون برابر با متوسط مجذور خطاها می‌باشد که از تقسیم RSS به درجه آزادی به‌دست می‌آید. نکته مهم در رگرسیون چندمتغیره این است که با افزایش تعداد متغیرهای توضیحی، معمولاً RSS کاهش و ESS افزایش می‌یابد. بدین ترتیب با افزایش تعداد متغیرهای توضیحی، قدرت توضیح‌دهندگی مدل و لذا مقدار R^2 افزایش می‌یابد.

اگر برای معادله $Y = \alpha + \beta X + u$ ضریب تعیین را با R_x^2 و برای معادله $Y = \alpha + \beta X + \gamma Z + u$ (که متغیر Z را اضافه کرده‌ایم) ضریب تعیین را با R_{xz}^2 نشان دهیم، رابطه بین R^2 ها عبارت است از^۱:

$$R_{xz}^2 = R_x^2 + (1 - R_x^2)r_{yz,x}^2 \quad (3-13)$$

که $r_{yz,x}^2$ ضریب همبستگی جزئی بین Y و Z است. بنابراین $R_{xz}^2 \geq R_x^2$ می‌باشد. اما هر متغیر جدیدی که به مدل اضافه می‌شود از یک طرف R^2 را افزایش و از طرف دیگر درجه آزادی را کاهش می‌دهد. به همین منظور از معیار دیگری به نام « R^2 تعدیل شده» استفاده می‌شود که آن را با \bar{R}^2 نشان می‌دهند. در محاسبه \bar{R}^2 اثر تعداد پارامترهای برآورد شده، تعدیل می‌شود به گونه‌ای که به جای تغییرات کل، از متوسط تغییرات استفاده می‌شود. بدیهی است که الزاماً $\bar{R}^2 \leq R^2$ است. همچنین ثابت می‌شود که برای هر متغیر جدیدی که به مدل اضافه می‌شود، اگر قدر مطلق t مربوطه، بزرگتر از ۱ باشد موجب افزایش \bar{R}^2 می‌شود. برای محاسبه σ^2 ، R^2 و \bar{R}^2 از روابط زیر می‌توان استفاده نمود که تا حدود زیادی مشابه با رگرسیون ساده می‌باشد:

$$\hat{\sigma}^2 = \frac{\sum (Y_i - \hat{Y}_i)^2}{n-K} = \frac{\sum e_i^2}{n-K} = \frac{RSS}{n-K} \quad (3-14)$$

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS}$$

$$\bar{R}^2 = 1 - \frac{RSS/(n-K)}{TSS/(n-1)} = 1 - \frac{n-1}{n-K} \frac{RSS}{TSS} = 1 - \frac{n-1}{n-K} (1 - R^2) \quad (3-15)$$

$$TSS = \sum y_i^2$$

$$ESS = \hat{\beta}_1 \sum x_{1i} y_i + \hat{\beta}_2 \sum x_{2i} y_i \quad (3-16)$$

$$RSS = TSS - ESS$$

به خاطر تخمین K پارامتر، درجه آزادی برابر با $n-K$ است که در اینجا $K=3$ است.

مثال ۳-۲: در مثال ۳-۱ خطای معادله رگرسیون و ضریب تعیین را حساب کنید.

^۱ Green, 2003, p. 34

$$TSS = \sum y_i^2 = 800$$

$$ESS = \hat{\beta}_1 \sum x_{1i} y_i + \hat{\beta}_2 \sum x_{2i} y_i \\ = (0/89605)(576) + (0/04253)(6040) = 773/006$$

$$RSS = 800 - 773/006 = 26/994$$

$$\hat{\sigma}^2 = \frac{RSS}{n-3} = \frac{26/994}{20-3} = 0/999778$$

$$R^2 = \frac{ESS}{TSS} = \frac{773/006}{800} = 0/9663$$

$$R^2 = 1 - \frac{n-1}{n-k} (1 - R^2) = 1 - \frac{20-1}{20-3} (1 - 0/9663) = 0/9622$$

۳-۵ معیارهای اطلاعات^۱

در محاسبه R^2 دیدیم که این معیار در خصوص افزودن یک متغیر توضیحی مورد استفاده قرار گیرد، زیرا افزودن یک متغیر اضافی، از یک طرف RSS را کاهش و از طرف دیگر درجه آزادی را کاهش می‌دهد. در واقع نفع و ضرر حاصل از افزودن یک متغیر را لحاظ می‌کند. مشابه این، معیارهای دیگری معرفی شده‌اند که معروف به معیار اطلاعات هستند. این معیارها نیز نفع و ضرر حاصل از افزودن یک یا چند متغیر را لحاظ می‌کنند. بدین معنی که هم نفع حاصل از کاهش RSS و هم زیان حاصل از کاهش درجه آزادی (افزایش K) را در نظر می‌گیرند. این معیارها شامل معیار اطلاعات آکائیک (AIC)، معیار اطلاعات بیزین شوارتز (SIC) و معیار اطلاعات حنان-کوئین ($HQIC$) می‌باشند:

$$AIC = \ln \hat{\sigma}^2 + \frac{K}{n}$$

$$SIC = \ln \hat{\sigma}^2 + \frac{K}{n} (\ln n) \quad (3-17)$$

$$HQIC = \ln \hat{\sigma}^2 + \frac{K}{n} \ln(\ln n)$$

که $\hat{\sigma}^2 = \frac{RSS}{n}$ می‌باشد. افزودن یک متغیر توضیحی به مدل موجب افزایش جمله اول (از طریق افزایش K) و موجب کاهش جمله دوم (از طریق کاهش $\hat{\sigma}^2$) می‌شود. بنابراین، هر چقدر معیارهای اطلاعات کمتر شوند، معیار بهتری برای انتخاب مدل است. در هر سه معیار، جمله اول شامل ضربی از $\frac{K}{n}$ است. این ضریب در معیار آکائیک کمتر از بقیه است، در حالی که در معیار

^۱Information criteria

حنان- کوئین بیشتر می باشد. در واقع معیار حنان- کوئین وزن بیشتری به $\frac{K}{n}$ می دهد و لذا جریمه بیشتری را به خاطر ورود یک متغیر در نظر می گیرد.

معیارهای اطلاعات در Eviews

هر معادله ای که با Eviews که تخمین می زنیم، خروجی آن هر سه معیار اطلاعات را ارائه می دهد. با مراجعه به جدول نتایج تخمین، مقدار معیارهای اطلاعات را می توان مشاهده نمود. اگر یک یا چند متغیر به مدل اضافه کنیم، آنگاه مقدار معیارهای اطلاعات تغییر خواهد کرد. اگر افزودن یک متغیر باعث کاهش معیار اطلاعات شود، در این صورت این متغیر را نگه می داریم و در غیر این صورت آن را کنار می گذاریم.

۳-۶ آزمون معنی دار بودن ضرایب معادله رگرسیون

مشابه رگرسیون یک متغیره، برای هر یک از ضرایب معادله رگرسیون می توان آزمون معنی دار بودن را انجام داد. همان طور که در رگرسیون یک متغیره دیدیم، اگر تعداد مشاهدات زیاد باشد، در صورتی که برای هر یک از ضرایب $2 \leq |t|$ باشد، آن ضریب در سطح ۵ درصد معنی دار است. ولی برای نمونه هایی که حجم آنها تقریباً کمتر از ۲۰ باشد بایستی مقدار t را با عدد بحرانی (t جدول) مقایسه کنیم. مقدار t از تقسیم ضریب موردنظر (یعنی $\hat{\beta}_i$) به انحراف معیار آن (یعنی $SE(\hat{\beta}_i) = \sqrt{\text{var}(\hat{\beta}_i)}$) به دست می آید. معمولاً برای سادگی، مقادیر t را داخل پرانتز و در زیر هر یک از ضرایب معادله رگرسیون می نویسند.

مثال ۳-۳ در مثال ۳-۲ معنی دار بودن ضرایب رگرسیون را بررسی کنید:

ابتدا واریانس $\hat{\beta}_1$ ، $\hat{\beta}_2$ و $\hat{\beta}_3$ را طبق روابط ۳-۱۱ حساب می کنیم:

$$r_{11}^2 = \frac{(440)^2}{(434)(49320)} = 0.4467$$

$$\text{var}(\hat{\beta}_1) = \frac{0.999778}{(1 - 0.4467)(434)} = 0.0024116, \quad SE(\hat{\beta}_1) = 0.0049116$$

$$\text{var}(\hat{\beta}_2) = \frac{0.999778}{(1 - 0.4467)(49320)} = 0.0000212, \quad SE(\hat{\beta}_2) = 0.0046067$$

$$\begin{aligned} \text{var}(\hat{\alpha}) &= 0.999778 \left(\frac{1}{40} + \frac{(9)^2 (49320) + (186)^2 (434) - 2(9)(186)(440)}{(1 - 0.4467)(434)(49320)} \right) \\ &= 0.0000212 \end{aligned}$$

$$\hat{Y}_i = 4/7912 + 0/89605X_{1i} + 0/04253X_{2i} \quad R^2 = 0/9662$$

$$(3/31) \quad (5/77) \quad (2/92) \quad \bar{R}^2 = 0/9622$$

چون برای هر یک از ضرایب، قدر مطلق t از عدد بحرانی (یعنی ۲/۰۸۶) بزرگتر است، همه ضرایب معنی دار هستند.

۳-۷ آزمون معنی دار بودن معادله رگرسیون (تحلیل واریانس)

تحلیل واریانس نشان می دهد که آیا کل معادله رگرسیون معنی دار است یا خیر. به عبارت دیگر آیا تغییرات توضیح داده شده توسط متغیرهای توضیحی در مقایسه با تغییرات توضیح داده نشده (یعنی خطاها) معنی دار می باشد یا نه. مشابه رگرسیون یک متغیره، می توان این آزمون را با F انجام داد که بحث آن دقیقاً مشابه مبحث تحلیل واریانس است که در فصل دوم بررسی شد. بدین منظور بایستی فرضیه $H_0: \beta_1 = \beta_2 = 0$ را آزمون کنیم.

$$F = \frac{S_E^2}{S_R^2} = \frac{S_E^2}{\hat{\sigma}^2} = \frac{ESS/(K-1)}{RSS/(n-K)} \quad (3-18)$$

$$= \frac{n-K}{K-1} \frac{ESS}{RSS} = \frac{n-K}{K-1} \frac{R^2}{1-R^2}$$

توجه شود که در اینجا K تعداد ضرایب تخمینی است که برابر با ۳ می باشد. هرگاه مقدار F از مقدار بحرانی آن بزرگتر باشد (یعنی $F \geq F_{\alpha, K-1, n-K}$) بدین معنی است که فرضیه H_0 رد می شود و رگرسیون معنادار است. بدیهی است که هرچه R^2 بزرگتر باشد، F نیز بزرگتر خواهد شد.

مثال ۴-۴: در مثال ۳-۳ معنی دار بودن معادله رگرسیون را انجام دهید.

بدین منظور فرضیه زیر را آزمون می کنیم:

$$H_0: \beta_1 = \beta_2 = 0$$

$$H_1: \beta_i \neq 0 \quad i = 1, 2$$

مقدار F برابر است با:

$$F = \frac{n-K}{K-1} \frac{ESS}{RSS} = \frac{20-3}{3-1} \times \frac{772/9817}{77/0.183} = 243/41$$

مقدار بحرانی F نیز برابر است با:

$$F_{\alpha, K-1, n-K} = F_{0.05, 2, 17} = 3/5 \Rightarrow (F \geq 3/5)$$

چون مقدار F در ناحیه بحرانی قرار دارد، لذا فرضیه H_0 رد می‌شود و رگرسیون معنی‌دار است.

۳-۸ تحلیل نتایج رگرسیون دو متغیره

فرض کنید معادله رگرسیون به صورت زیر باشد:

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + u_i \quad (3-19)$$

β_1 تأثیر X_1 بر Y است و نشان می‌دهد که اگر X_1 یک واحد تغییر کند، Y به اندازه β_1 تغییر خواهد کرد. حال فرض کنید به جای (۳-۱۹) به اشتباه معادله زیر را برآورد کنیم:

$$Y_i = b_1 + b_2 X_{1i} + \varepsilon_{1i} \quad (3-20)$$

b_1 تأثیر X_1 بر Y است و ε_{1i} جملهٔ اخلال را نشان می‌دهد. اما سؤال این است که چه تفاوتی بین b_1 و β_1 است.

توجه داریم که $\hat{\beta}_1$ تخمین زنندهٔ نااریب (بدون تورش) از β_1 می‌باشد. در حالی که ما به جای آن \hat{b}_1 را برآورد نموده‌ایم که \hat{b}_1 برآورد کنندهٔ b_1 است نه β_1 . می‌توان نشان داد که \hat{b}_1 و $\hat{\beta}_1$ با هم برابر نیستند. فقط در یک حالت این دو برابرند و آن زمانی است که X_1 و X_2 هیچ ارتباطی با هم نداشته باشند و ضریب همبستگی آنها (r_{12}) صفر باشد. اما عملاً چنین نیست و ضریب همبستگی X_1 و X_2 معمولاً مخالف صفر است. بدین منظور معادله زیر را در نظر بگیرید:

$$X_{2i} = B_1 + B_2 X_{1i} + \varepsilon_{2i} \quad (3-21)$$

ضریب B_1 بیانگر اثر X_1 بر X_2 است. اگر X_1 و X_2 کاملاً مستقل باشند، آنگاه B_1 برابر صفر خواهد بود و در این صورت b_1 و β_1 نیز برابرند. حال (۳-۲۱) را در (۳-۱۹) جایگزین می‌کنیم:

$$\begin{aligned} Y_i &= \alpha + \beta_1 X_{1i} + \beta_2 (B_1 + B_2 X_{1i} + \varepsilon_{2i}) + u_i \\ &= (\alpha + \beta_2 B_1) + (\beta_1 + \beta_2 B_2) X_{1i} + (u_i + \beta_2 \varepsilon_{2i}) \end{aligned} \quad (3-22)$$

مقایسه (۳-۲۲) با (۳-۲۰) نشان می‌دهد که $b_1 = \alpha + \beta_2 B_1$ و $b_2 = \beta_1 + \beta_2 B_2$ است. بنابراین وقتی معادله (۳-۲۰) را به جای معادله (۳-۱۹) برآورد کنیم به این معنی است که به جای β_1 ، ضریب b_1 را برآورد نموده‌ایم که قطعاً با β_1 برابر نیست:

$$b_1 = \beta_1 + \beta_2 B_1 \quad (3-23)$$

حال تفسیر b_1 چگونه است. b_1 شامل دو اثر است: یکی اثر X_1 بر Y با ثابت نگه داشتن X_2 که معادل با β_1 می باشد. دیگری تأثیر غیرمستقیم X_1 بر Y است که از طریق تأثیر X_2 بر X_1 روی Y اعمال می شود و برابر با $\beta_2 B_1$ می باشد. لذا b_1 را می توان اثر ناخالص X_1 بر Y دانست:

$$(3-24) \quad \underbrace{\text{اثر غیرمستقیم } X_1 \text{ از طریق } X_2 \text{ بر } Y}_{\beta_2 B_1} + \underbrace{\text{اثر خالص یا مستقیم } X_1 \text{ بر } Y}_{\beta_1} = \underbrace{\text{اثر ناخالص } X_1 \text{ بر } Y}_{b_1}$$

بنابراین اگر مدل واقعی به صورت (۳-۱۹) باشد و ما به اشتباه X_2 را از معادله حذف کنیم و معادله (۳-۲۰) برآورد نماییم. در این صورت اثر X_1 بر Y را به صورت غیر واقعی برآورد نموده ایم که مقدار خطا برابر با $\beta_2 B_1$ است. به عبارت دیگر، b_1 اثر X_1 بر Y بدون ثابت نگه داشتن X_2 است و β_1 اثر X_1 بر Y با ثابت نگه داشتن X_2 می باشد.

مثال ۳-۵ در مثال ۳-۱ اثر ناخالص، مستقیم و غیرمستقیم X_1 بر Y را به دست آورده ایم. در اینجا باید $b_1 = \beta_1 + \beta_2 B_1$ را برآورد نماییم. اثر ناخالص X_1 بر Y از معادله زیر به دست می آید:

$$\begin{aligned} \hat{Y}_i &= \hat{b}_1 + \hat{b}_2 X_{2i} \\ \hat{b}_1 &= \frac{\sum X_{2i} Y_i}{\sum X_{2i}^2} = \frac{576}{434} = 1/3272 \\ \hat{b}_2 &= \bar{Y} - \hat{b}_1 \bar{X}_2 = 20 - (1/3272)(9) = 8/0553 \\ \hat{Y}_i &= 1/3272 + 8/0553 X_{2i} \end{aligned}$$

اثر ناخالص X_1 بر Y در مثال ۳-۱ برابر با $\hat{\beta}_1 = 1/89605$ به دست آمد. از طرف دیگر برای تعیین B_1 داریم:

$$\begin{aligned} \hat{X}_{2i} &= \hat{B}_1 + \hat{B}_2 \hat{X}_{1i} \\ \hat{B}_1 &= \frac{\sum X_{2i} X_{1i}}{\sum X_{1i}^2} = \frac{440}{434} = 10/1382 \\ \hat{B}_2 &= \bar{X}_2 - \hat{B}_1 \bar{X}_1 = 168 - (10/1382)(9) = 76/7558 \\ \hat{X}_{2i} &= 76/7558 + 10/1382 X_{1i} \end{aligned}$$

بنابراین اثر ناخالص (کل) X_1 بر Y برابر با $\hat{b}_1 = 1/3272$ و اثر خالص برابر با $\hat{\beta}_1 = 0/89605$ و اثر غیر مستقیم برابر با $0/4312$ می باشد.

نتایج فوق را می توان با استفاده از معادله (۹-۳) نیز به دست آورد. بدین منظور $\hat{\beta}_1$ را به صورت زیر می نویسیم:

$$\sum x_{1i}y_i - \hat{\beta}_1 \sum x_{1i}^2 - \hat{\beta}_2 \sum x_{1i}x_{2i} = 0 \Rightarrow \hat{\beta}_1 = \frac{\sum x_{1i}y_i}{\sum x_{1i}^2} - \hat{\beta}_2 \frac{\sum x_{1i}x_{2i}}{\sum x_{1i}^2}$$

ملاحظه می شود که در فرمول فوق، $\hat{b}_1 = \frac{\sum x_{1i}y_i}{\sum x_{1i}^2}$ و $\hat{b}_2 = \frac{\sum x_{1i}x_{2i}}{\sum x_{1i}^2}$ و لذا $\hat{\beta}_1$ برابر است با:

$$\hat{\beta}_1 = \hat{b}_1 - \hat{\beta}_2 \hat{b}_2$$

طبق رابطه فوق، اثر خالص X_1 بر Y ، یعنی $(\hat{\beta}_1)$ برابر با اثر ناخالص (\hat{b}_1) منهای اثر X_2 بر Y از طریق X_1 می باشد.

۹-۳ تحلیل همبستگی چند متغیره

ضرایب همبستگی بیانگر روابط خطی بین متغیرها هستند. به عنوان مثال در رگرسیون دو متغیره، r_{12} ضریب همبستگی بین X_1 و X_2 را نشان می دهد. ضریب همبستگی بین X_1 و Y را با r_{1y} و بین X_2 و Y را با r_{2y} نشان می دهیم. هر یک از این ضرایب همبستگی را با استفاده از فرمول «ضریب همبستگی ساده» می توان محاسبه نمود.

حال با توجه به اینکه ۳ متغیر X_1 ، X_2 و Y را داریم، تا چه اندازه r_{1y} بیانگر همبستگی واقعی بین X_1 و Y است. در حالی که X_2 نیز با هر دو متغیرها همبستگی دارد. این بحث دقیقاً مشابه آن چیزی است که در رابطه با رگرسیون و اثر واقعی X_1 بر Y بررسی نمودیم.

r_{1y} بیانگر همبستگی بین X_1 و Y در حالتی است که هیچ توجهی به X_2 نداشته باشیم. در واقع به طور ضمنی فرض کرده ایم که X_2 ثابت است، در حالی که چنین نیست. بنابراین r_{1y} تصویر غیر واقعی از همبستگی بین X_1 و Y را ارائه می دهد. بدین ترتیب لازم است که اثر X_2 را به طور کامل حذف کنیم تا بدین ترتیب بتوان همبستگی واقعی بین X_1 و Y را به دست آورد. این ضریب

همبستگی را «ضریب همبستگی جزئی» بین X_1 و Y می‌گوییم که با $r_{1y.2}$ نشان می‌دهیم که به معنی ضریب همبستگی بین X_1 و Y با ثابت نگه داشتن X_2 است.

$r_{1y.2}$: ضریب همبستگی جزئی بین X_1 و Y با ثابت نگه داشتن X_2

$r_{2y.1}$: ضریب همبستگی جزئی بین X_2 و Y با ثابت نگه داشتن X_1

$r_{12.y}$: ضریب همبستگی جزئی بین X_1 و X_2 با ثابت نگه داشتن Y

برای محاسبه «ضرایب همبستگی جزئی» روابط نسبتاً ساده‌ای وجود دارد که آنها را می‌توان بر حسب «ضرایب همبستگی ساده» بیان نمود.

$$\begin{aligned} r_{1y.2} &= \frac{r_{1y} - r_{12}r_{2y}}{\sqrt{(1-r_{12}^2)(1-r_{2y}^2)}} \\ r_{2y.1} &= \frac{r_{2y} - r_{12}r_{1y}}{\sqrt{(1-r_{12}^2)(1-r_{1y}^2)}} \\ r_{12.y} &= \frac{r_{12} - r_{1y}r_{2y}}{\sqrt{(1-r_{1y}^2)(1-r_{2y}^2)}} \end{aligned} \quad (3-25)$$

تفسیر ضرایب همبستگی جزئی را می‌توان با استفاده از روابط (۳-۲۵) ارائه نمود. به عنوان مثال در ضریب همبستگی جزئی $r_{1y.2}$ حتی اگر ضریب همبستگی ساده صفر باشد ($r_{1y} = 0$)، ضریب همبستگی جزئی $r_{1y.2}$ صفر نخواهد بود، زیرا:

$$r_{1y} = 0 \Rightarrow r_{1y.2} = -\frac{r_{12}r_{2y}}{\sqrt{(1-r_{12}^2)(1-r_{2y}^2)}}$$

فقط در صورتی ضریب همبستگی جزئی صفر می‌شود که r_{12} یا r_{2y} نیز صفر شود، یعنی X_1 با X_2 و همچنین Y با X_2 رابطه‌ای نداشته باشد.

حال اگر $r_{12} = 0$ باشد در این صورت همبستگی جزئی بین X_1 و Y به صورت زیر است:

$$r_{12} = 0 \Rightarrow r_{1y.2} = \frac{r_{1y}}{\sqrt{1-r_{2y}^2}}$$

اگر علاوه بر $r_{12} = 0$ ، ضریب همبستگی ساده بین X_2 و Y نیز صفر باشد ($r_{2y} = 0$)، در این صورت ضریب همبستگی جزئی و ضریب همبستگی ساده برابر خواهند بود:

$$r_{12} = r_{21} = 0 \Rightarrow r_{12,2} = r_{12}$$

اما بین ضرایب تعیین و ضرایب همبستگی نیز روابطی وجود دارد که عبارتند از:

$$R^2 = \frac{r_{12}^2 + r_{23}^2 - 2r_{12}r_{23}r_{13}}{1 - r_{13}^2} \quad (3-26)$$

$$= r_{12}^2 + (1 - r_{13}^2)r_{23}^2 = r_{23}^2 + (1 - r_{23}^2)r_{12}^2$$

مثال ۳-۶: در مثال ۳-۱ ضرایب همبستگی ساده و جزئی را حساب کنید:

ضرایب همبستگی ساده عبارتند از:

$$r_{12} = \frac{2400}{\sqrt{(434)(49320)}} = 0.951 \quad r_{12}^2 = 0.904$$

$$r_{13} = \frac{576}{\sqrt{(434)(800)}} = 0.977 \quad r_{13}^2 = 0.954$$

$$r_{23} = \frac{6040}{\sqrt{(49320)(800)}} = 0.962 \quad r_{23}^2 = 0.925$$

و ضرایب همبستگی جزئی، طبق روابط (۶۳-۲۰) عبارتند از:

$$r_{12,3} = \frac{0.951 - (0.962)(0.951)}{\sqrt{(1 - 0.925)(1 - 0.904)}} = 0.736$$

$$r_{23,1} = \frac{0.962 - (0.977)(0.951)}{\sqrt{(1 - 0.954)(1 - 0.904)}} = 0.498$$

$$r_{13,2} = \frac{0.977 - (0.977)(0.962)}{\sqrt{(1 - 0.954)(1 - 0.925)}} = 0.191$$

۳-۱۰ مدل K متغیره

در حالت کلی معادله زیر را در نظر بگیرید که دارای K متغیر توضیحی می باشد:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_K X_{iK} + u_i \quad (3-27)$$

در این معادله β_1 عرض از مبدأ می‌باشد که در واقع ضریب متغیر X_1 است و X_1 نیز برداری با عناصر واحد می‌باشد. حال مدل فوق را به صورت ماتریسی می‌نویسیم:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & \cdots & X_{K1} \\ 1 & X_{12} & \cdots & X_{K2} \\ \vdots & \vdots & & \vdots \\ 1 & X_{1n} & \cdots & X_{Kn} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} \quad (3-28)$$

بنابراین مدل (3-28) به طور خلاصه عبارت است از:

$$y = X\beta + u \quad (3-29)$$

y و بردارهای ستونی با ابعاد $n \times 1$ هستند. X ماتریس $n \times K$ و β بردار ستونی $K \times 1$ می‌باشد. در اینجا نیز بایستی β به گونه‌ای برآورد شود که مجموع مجذور خطا (RSS) حداقل شود:

$$RSS = \sum_{i=1}^n e_i^2 = e'e, \quad e = y - \hat{y} = y - X\hat{\beta}$$

e بردار ستونی خطاها و e' ترانسپوز آن می‌باشد. با جایگذاری به جای e ، خواهیم داشت:

$$\begin{aligned} RSS = e'e &= (y - X\hat{\beta})'(y - X\hat{\beta}) \\ &= y'y - y'X\hat{\beta} + \hat{\beta}'X'X\hat{\beta} \end{aligned} \quad (3-30)$$

برای حداقل شدن $e'e$ ، نسبت به $\hat{\beta}$ مشتق می‌گیریم:

$$\frac{\partial e'e}{\partial \hat{\beta}} = -y'X' + \hat{\beta}'X'X = 0 \quad (3-31)$$

با حل این معادله، $\hat{\beta}$ به دست می‌آید:

$$\hat{\beta} = (X'X)^{-1}(X'y) \quad (3-32)$$

$\hat{\beta}$ تخمین زننده OLS برای β است. این تخمین زننده چون تابع خطی از u است، لذا دارای امید ریاضی β و واریانس $\sigma^2(X'X)^{-1}$ می‌باشد. بدین منظور ابتدا به جای Y قرار می‌دهیم:

$$\begin{aligned} \hat{\beta} &= (X'X)^{-1}(X'y) = (X'X)^{-1}X'(X\beta + u) \\ &= \beta + (X'X)^{-1}X'u \end{aligned}$$

امید ریاضی $\hat{\beta}$ عبارت است از:

$$\begin{aligned} E(\hat{\beta}) &= E(\beta + (X'X)^{-1}X'u) \\ &= \beta + (X'X)^{-1}X'E(u) = \beta, \quad E(u) = 0 \end{aligned}$$

واریانس $\hat{\beta}$ عبارت است از:

$$\begin{aligned}\text{var}(\hat{\beta}) &= E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'] \\ &= E\left\{[(X'X)^{-1}X'u][(X'X)^{-1}X'u]'\right\} \\ &= E\left\{(X'X)^{-1}X'uu'X(X'X)^{-1}\right\} \\ &= (X'X)^{-1}X'E(uu')X(X'X)^{-1}\end{aligned}$$

$E(uu')$ ماتریس واریانس-کوواریانس u است که آن را با Σ نشان می‌دهیم:

$$\begin{aligned}E(uu') &= \Sigma = E\begin{bmatrix} u_1 \\ \vdots \\ u_n \end{bmatrix} \begin{bmatrix} u_1 & \dots & u_n \end{bmatrix} \\ &= E\begin{bmatrix} u_1^2 & u_1u_2 & \dots & u_1u_n \\ u_2u_1 & u_2^2 & \dots & u_2u_n \\ \vdots & \vdots & \ddots & \vdots \\ u_nu_1 & u_nu_2 & \dots & u_n^2 \end{bmatrix} = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 I_n\end{aligned}$$

زیرا $E(u_i^2) = \sigma^2$ و $E(u_iu_j) = 0$ است. بنابراین، واریانس $\hat{\beta}$ برابر است با:

$$\begin{aligned}\text{var}(\hat{\beta}) &= (X'X)^{-1}X'(\sigma^2 I_n)X(X'X)^{-1} \\ &= \sigma^2 (X'X)^{-1}X'X(X'X)^{-1} \\ &= \sigma^2 (X'X)^{-1}\end{aligned}\tag{۳-۳۳}$$

بدین ترتیب واریانس $\hat{\beta}_k$ برابر با حاصل ضرب σ^2 در عنصر k ام قطر اصلی ماتریس $(X'X)^{-1}$ می‌باشد. سایر عناصر نیز کوواریانس بین ضرایب را نشان می‌دهد. به‌طور کلی، ماتریس $\sigma^2 (X'X)^{-1}$ را ماتریس واریانس-کوواریانس ضرایب می‌گویند.

ماهیت این ماتریس در مثال ۳-۷ نشان داده شده است. از آنجا که σ^2 مجهول است، لذا از تخمین آن استفاده می‌کنیم که برابر است با:

$$\hat{\sigma}^2 = \frac{RSS}{n-K} = \frac{e'e}{n-K}\tag{۳-۳۴}$$

$n-K$ برابر با درجه آزادی است، زیرا K پارامتر را برآورد کرده‌ایم.

مثال ۷-۳. فرض کنید که بر اساس داده‌های ۱۵ سال برای سه متغیر X_1 ، X_2 و Y مقادیر زیر به دست آمده است:

$$(XX')^{-1} = \begin{bmatrix} 2/5 & 3/5 & -1/5 \\ 3/5 & 1/5 & 6/5 \\ -1/5 & 6/5 & 4/3 \end{bmatrix}, \quad X'y = \begin{bmatrix} -3/5 \\ 2/2 \\ 0/6 \end{bmatrix}$$

$$e'e = 10/96$$

بر اساس این مشاهدات، $\hat{\beta}$ برابر است با:

$$\hat{\beta} = (X'X)^{-1}(X'y) = \begin{bmatrix} 1/1 \\ -4/4 \\ 19/88 \end{bmatrix}$$

تخمین واریانس u برابر است با:

$$\hat{\sigma}^2 = \frac{e'e}{n-K} = \frac{10/96}{15-3} = 0/91$$

بنابراین، واریانس $\hat{\beta}$ عبارت است از:

$$\text{var}(\hat{\beta}) = \hat{\sigma}^2 (X'X)^{-1} = 0/91 \begin{bmatrix} 2/5 & 3/5 & -1/5 \\ 3/5 & 1/5 & 6/5 \\ -1/5 & 6/5 & 4/3 \end{bmatrix}$$

$$= \begin{bmatrix} 1/82 & 3/19 & -0/91 \\ 3/19 & 0/91 & 5/92 \\ -0/91 & 5/92 & 3/91 \end{bmatrix} = \begin{bmatrix} \text{var}(\hat{\beta}_1) & \text{cov}(\hat{\beta}_1, \hat{\beta}_2) & \text{cov}(\hat{\beta}_1, \hat{\beta}_3) \\ \text{cov}(\hat{\beta}_2, \hat{\beta}_1) & \text{var}(\hat{\beta}_2) & \text{cov}(\hat{\beta}_2, \hat{\beta}_3) \\ \text{cov}(\hat{\beta}_3, \hat{\beta}_1) & \text{cov}(\hat{\beta}_3, \hat{\beta}_2) & \text{var}(\hat{\beta}_3) \end{bmatrix}$$

بدین ترتیب واریانس ضرایب عبارت است از:

$$\text{var}(\hat{\beta}_1) = 1/82, \quad \text{var}(\hat{\beta}_2) = 0/91, \quad \text{var}(\hat{\beta}_3) = 3/91$$

معادله رگرسیون عبارت است از:

$$\hat{Y}_i = 1/10 - 4/40 X_{1i} + 19/88 X_{2i} \\ (0/81) \quad (-4/6) \quad (10/5)$$

برآورد رگرسیون چند متغیره با Eviews

فایل data3

برای برآورد معادله رگرسیون، مشابه رگرسیون یک متغیره می‌توان عمل نمود. در پنجره فرمان، معادله مورد نظر را به صورت $LS \ Y \ C \ X1 \ X2$ وارد می‌کنیم. در اینجا Y متغیر وابسته، C عرض از مبدا و $X1$ و $X2$ متغیرهای توضیحی هستند. بعد از وارد نمودن عبارت مذکور، با زدن کلید Enter نتایج تخمین در پنجره Equation ارائه می‌شود. تمامی نتایج مشابه رگرسیون یک متغیره می‌باشد.

فرض کنید که می‌خواهیم رگرسیون سرمایه‌گذاری (I) را روی نرخ بهره حقیقی (RR)، تغییرات درآمد ملی بدون تست (dY) و سرمایه‌گذار در سال قبل (I(-1)) برآورد کنیم، بدین منظور از دستور زیر استفاده می‌کنیم:

LS I C RR dY I(-1)

با زدن کلید Enter نتایج به صورت زیر نشان داده می‌شود:

Equation: UNTITLED Workfile: DATA5:Untitled1

ViewProcObjectPrintNameFreezeEstimateForecastStatsResids

Dependent Variable: I
Method: Least Squares
Date: 09/23/11 Time: 19:17
Sample (adjusted): 1352 1386
Included observations: 35 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob
C	5742.205	5095.942	1.126819	0.2685
RR	-246.7890	200.1556	-1.232988	0.2268
DYNO	1.187917	0.158345	7.502104	0.0000
I(-1)	0.819486	0.052327	15.66052	0.0000
R-squared	0.947025	Mean dependent var	90623.63	
Adjusted R-squared	0.941899	S.D. dependent var	35779.97	
S.E. of regression	8624.471	Akaike info criterion	21.06981	
Sum squared resid	2.31E+09	Schwarz criterion	21.24756	
Log likelihood	-364.7216	Hannan-Quinn criter.	21.13117	
F-statistic	184.7287	Durbin-Watson stat	1.655497	
Prob(F-statistic)	0.000000			

جدول فوق نشان می‌دهد که فرض از مبدأ، معنادار نیست زیرا برای آن $t = 1/12$ است. ضریب نرخ بهره حقیقی برابر با $-246/8$ است که علامت منفی دارد و مطابق با تئوری است، اما از لحاظ آماری معنادار نیست. ضریب تغییرات درآمد ملی، هم مثبت و هم معنادار است. متغیر سرمایه‌گذاری تأخیری نیز دارای ضریب مثبت و معنادار است. R^2 برابر با $0/947$ و \bar{R}^2 نیز برابر با $0/942$ می‌باشد. مقدار F نیز برابر با $184/7$ است که کاملاً معنادار می‌باشد.

ماتریس $X'X$ نقش مهمی در برآورد β دارد. برای بررسی خواص ماتریس $X'X$ ، ابتدا متغیرها را بر حسب انحراف از میانگین می‌نویسیم. بدین منظور معادله (۳-۲۷) را جمع زده و بر تقسیم می‌کنیم:

$$\sum Y_i = n\beta_1 + \beta_2 \sum X_{1i} + \dots + \beta_K \sum X_{Ki} + \sum u_i$$

$$\bar{Y} = \beta_1 + \beta_2 \bar{X}_1 + \dots + \beta_K \bar{X}_K + \bar{u} \quad (3-35)$$

حال معادله فوق را از (۳-۲۷) کم می کنیم:

$$Y_i - \bar{Y} = \beta_1(X_{i1} - \bar{X}_1) + \dots + \beta_K(X_{iK} - \bar{X}_K) + (u_i - \bar{u})$$

متغیرهایی را که بر حسب انحراف از میانگین هستند با حروف کوچک نشان می دهیم:

$$y_i = \beta_1 x_{i1} + \dots + \beta_K x_{iK} + v_i \quad (3-27')$$

شکل ماتریسی معادله فوق عبارت است از (مشابه معادله ۳-۲۹):

$$y_* = X_* \beta_* + v \quad (3-29')$$

β_* یک بردار $(K-1) \times 1$ و X_* نیز $n \times (K-1)$ می باشد که شامل داده های x_1 تا x_K است. در اینجا نیز مجموع مجذور خطاها $(e'e)$ را حساب کرده و با مشتق گیری نسبت به $\hat{\beta}_*$ تخمین پارامترها را به دست می آوریم:

$$e = y_* - \hat{y}_* = y_* - X_* \hat{\beta}_*$$

$$e'e = (y_* - X_* \hat{\beta}_*)'(y_* - X_* \hat{\beta}_*) = y_*' y_* - y_*' X_* \hat{\beta}_* + \hat{\beta}_*' (X_*' X_*) \hat{\beta}_*$$

$$\frac{\partial e'e}{\partial \hat{\beta}_*} = 0 \rightarrow \hat{\beta}_* = (X_*' X_*)^{-1} X_*' y_* \quad (3-33')$$

با تخمین $\hat{\beta}_*$ ، تخمین $\hat{\beta}_1$ تا $\hat{\beta}_K$ به دست می آید. $\hat{\beta}_1$ نیز از رابطه زیر تعیین می شود:

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}_2 - \dots - \hat{\beta}_K \bar{X}_K$$

همان طور که اشاره شد، ماتریس X_* در اینجا شامل داده های x_1 تا x_K می باشد:

$$X_* = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1K} \\ x_{21} & x_{22} & \dots & x_{2K} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nK} \end{bmatrix} \quad (3-36)$$

ماتریس $X_*' X_*$ عبارت است از:

$$X'_*X_* = \begin{bmatrix} \sum x_{vi}^2 & \sum x_{vi}x_{vi} & \cdots & \sum x_{vi}x_{Ki} \\ \sum x_{vi}x_{vi} & \sum x_{vi}^2 & \cdots & \sum x_{vi}x_{Ki} \\ \vdots & \vdots & \ddots & \vdots \\ \sum x_{Ki}x_{vi} & \sum x_{Ki}x_{vi} & \cdots & \sum x_{Ki}^2 \end{bmatrix} \quad (3-37)$$

اگر هر یک از عناصر ماتریس X'_*X_* را بر n تقسیم کنیم آن گاه ماتریسی به دست می آید که قطر اصلی آن واریانس X ها و سایر عناصر، کوواریانس بین X ها را نشان می دهد:

$$\frac{1}{n}X'_*X_* = \begin{bmatrix} S_v^2 & S_{vv} & \cdots & S_{vK} \\ S_{vv} & S_v^2 & \cdots & S_{vK} \\ \vdots & \vdots & \ddots & \vdots \\ S_{Kv} & S_{Kv} & \cdots & S_K^2 \end{bmatrix} \quad (3-38)$$

S_i^2 واریانس X_i و S_{ij} کوواریانس X_i و X_j می باشد.

حال برای سادگی، بحث را بر اساس رگرسیون دو متغیره ادامه می دهیم. در این صورت X'_*X_* و X'_*y_* عبارتند از:

$$X'_*X_* = \begin{bmatrix} \sum x_{vi}^2 & \sum x_{vi}x_{vi} \\ \sum x_{vi}x_{vi} & \sum x_{vi}^2 \end{bmatrix}; \quad X'_*y_* = \begin{bmatrix} \sum x_{vi}y_i \\ \sum x_{vi}y_i \end{bmatrix}$$

$(X'_*X_*)^{-1}$ نیز عبارت است از:

$$\begin{aligned} (X'_*X_*)^{-1} &= \frac{1}{\sum x_{vi}^2 \sum x_{vi}^2 - (\sum x_{vi}x_{vi})^2} \begin{bmatrix} \sum x_{vi}^2 & -\sum x_{vi}x_{vi} \\ -\sum x_{vi}x_{vi} & \sum x_{vi}^2 \end{bmatrix} \\ &= \frac{1}{(1-r_{vv}^2) \sum x_{vi}^2 \sum x_{vi}^2} \begin{bmatrix} \sum x_{vi}^2 & -\sum x_{vi}x_{vi} \\ -\sum x_{vi}x_{vi} & \sum x_{vi}^2 \end{bmatrix} \end{aligned} \quad (3-39)$$

$$r_{vv}^2 = \frac{(\sum x_{vi}x_{vi})^2}{\sum x_{vi}^2 \sum x_{vi}^2}$$

r_{vv} ضریب همبستگی X_v و X_v است.

بر اساس ماتریس $(X'_*X_*)^{-1}$ می توان سه حالت را بررسی نمود:

الف) اگر بین X_v و X_v رابطه خطی کامل باشد، در این صورت $r_{vv}^2 = 1$ خواهد بود و لذا $(X'_*X_*)^{-1}$ قابل محاسبه نیست و امکان برآورد ضرایب وجود ندارد. در این حالت به عنوان

مثال $X_{vi} = aX_{vi}$ است، یعنی یکی از ستون‌های ماتریس X_* ضریبی از ستون دیگر است. در این صورت ما فقط راجع به یکی از متغیرهای توضیحی دارای اطلاعات هستیم و در مورد دیگری هیچ اطلاعاتی نداریم و لذا فقط یکی از ضرایب آنها (ضریب X_v یا ضریب X_r) قابل برآورد است. عبارت دیگر اطلاعات ما برای برآورد دو ضریب، کافی نیست. اگر $X_{vi} = aX_{vi}$ باشد، خواهیم داشت:

$$\begin{aligned} Y_i &= \beta_1 + \beta_v X_{vi} + \beta_r (aX_{vi}) + u_i \\ &= \beta_1 + (\beta_v + \beta_r a) X_{vi} + u_i \\ &= \beta_1 + \alpha_v X_{vi} + u_i \end{aligned}$$

بنابراین فقط ضریب X_r قابل برآورد است و امکان برآورد ضریب X_v وجود ندارد. (ب) اگر X_v و X_r مستقل خطی باشند، در این صورت $r_{vv}^* = 0$ است که بدیهی است $\sum x_{vi} x_{vi} = 0$ می‌باشد. در این حالت، $(X'_* X_*)^{-1}$ و برآورد ضرایب X_v و X_r عبارت است از:

$$\hat{\beta}_* = \begin{bmatrix} \hat{\beta}_r \\ \hat{\beta}_v \end{bmatrix} = \frac{1}{\sum x_{vi}^2 \sum x_{vi}^2} \begin{bmatrix} \sum x_{vi}^2 & 0 \\ 0 & \sum x_{vi}^2 \end{bmatrix} \begin{bmatrix} \sum x_{vi} y_i \\ \sum x_{vi} y_i \end{bmatrix} = \begin{bmatrix} \frac{\sum x_{vi} y_i}{\sum x_{vi}^2} \\ \frac{\sum x_{vi} y_i}{\sum x_{vi}^2} \end{bmatrix} \quad (3-40)$$

نتایج فوق نشان می‌دهد که تخمین ضرایب β_v و β_r مشابه تخمین آنها در معادلات رگرسیون یک متغیره است، یعنی β_v از معادله $Y_i = \alpha + \beta_v X_{vi} + u_i$ و β_r از معادله $Y_i = \alpha + \beta_r X_{vi} + u_i$ به دست می‌آید.

(ج) اگر X_v و X_r رابطه خطی غیر کامل داشته باشند به گونه‌ای که $0 < r_{vv}^* < 1$ باشد، در این حالت تخمین $\hat{\beta}_v$ و $\hat{\beta}_r$ به هم وابسته هستند. بدین منظور معادلات زیر را داریم:

$$(X'_* X_*) \hat{\beta}_* = X'_* y_* \Rightarrow \begin{bmatrix} \sum x_{vi}^2 & \sum x_{vi} x_{vi} \\ \sum x_{vi} x_{vi} & \sum x_{vi}^2 \end{bmatrix} \begin{bmatrix} \hat{\beta}_r \\ \hat{\beta}_v \end{bmatrix} = \begin{bmatrix} \sum x_{vi} y_i \\ \sum x_{vi} y_i \end{bmatrix} \quad (3-41)$$

$$\hat{\beta}_r \sum x_{vi}^2 + \hat{\beta}_v \sum x_{vi} x_{vi} = \sum x_{vi} y_i \Rightarrow \hat{\beta}_r = \frac{\sum x_{vi} y_i}{\sum x_{vi}^2} - \frac{\sum x_{vi} x_{vi}}{\sum x_{vi}^2} \hat{\beta}_v \quad (3-42)$$

$$\hat{\beta}_r \sum x_{vi} x_{vi} + \hat{\beta}_v \sum x_{vi}^2 = \sum x_{vi} y_i \Rightarrow \hat{\beta}_v = \frac{\sum x_{vi} y_i}{\sum x_{vi}^2} - \frac{\sum x_{vi} x_{vi}}{\sum x_{vi}^2} \hat{\beta}_r \quad (3-43)$$

نتایج فوق نشان می‌دهد که تخمین هر ضریب، وابسته به دیگری است. این بدان معنا است که اثر X_v بر Y معادل با β_v است که از معادله $Y_i = \beta_1 + \beta_v X_{vi} + \beta_w X_{wi} + u_i$ تعیین می‌شود که در آن X_w وجود دارد. حال اگر β_v را از معادله $Y_i = \beta_1 + \beta_v X_{vi} + u_i$ به دست آوریم، دارای تورش خواهد بود و با β_v واقعی برابر نخواهد بود.

اگر از (۳-۴۳) به جای $\hat{\beta}_v$ در (۳-۴۲) قرار دهیم، خواهیم داشت:

$$\hat{\beta}_v = \frac{\sum x_{vi} \sum x_{vi} y_i - \sum x_{vi} x_{wi} \sum x_{wi} y_i}{\sum x_{vi}^2 \sum x_{vi}^2 - (\sum x_{vi} x_{wi})^2} \quad (3-44)$$

رابطه (۳-۴۴) را می‌توان با توجه به تعریف r_{vw}^2 به صورت زیر نوشت:

$$\hat{\beta}_v = \frac{1}{1 - r_{vw}^2} \left(\underbrace{\frac{\sum x_{vi} y_i}{\sum x_{vi}^2}}_{\hat{b}_v} - \underbrace{\frac{\sum x_{vi} x_{wi}}{\sum x_{vi}^2}}_{\hat{\alpha}_v} \underbrace{\frac{\sum x_{wi} y_i}{\sum x_{wi}^2}}_{\hat{b}_w} \right) \quad (3-45)$$

$\hat{\alpha}_v$ و \hat{b}_v به ترتیب از معادلات (۳-۴۶)، (۳-۴۷) و (۳-۴۸) به دست می‌آیند:

$$Y_i = b_1 + b_v X_{vi} + u_i \quad (3-46)$$

$$X_{wi} = \alpha_1 + \alpha_v X_{vi} + \varepsilon_i \quad (3-47)$$

$$Y_i = a_1 + b_v X_{vi} + v_i \quad (3-48)$$

رابطه (۳-۴۵) نشان می‌دهد که تخمین ضریب X_v وابسته به رابطه X_v و X_w است که این وابستگی توسط ضریب همبستگی آنها (یعنی r_{vw}) و همچنین توسط $\hat{\alpha}_v$ توصیف می‌شود.

۳-۱۱ رگرسیون مقید و تخمین‌زننده‌های مقید

به عنوان یک مثال ساده فرض کنید که در معادله رگرسیون $Y_i = \beta_1 + \beta_v X_{vi} + \beta_w X_{wi} + u_i$ با قید $\beta_v + \beta_w = 1$ مواجه‌ایم. این یک رگرسیون مقید است که ضرایب آن از مسئله زیر به دست می‌آید:

$$\begin{aligned} \min \sum e_i^2 &= \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_v X_{vi} - \hat{\beta}_w X_{wi})^2 \\ \text{st. } \hat{\beta}_v + \hat{\beta}_w &= 1 \end{aligned} \quad (3-49)$$

برای حل این مسئله، تابع لاگرانژ را تشکیل می‌دهیم:

$$L = \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_r X_{ri} - \hat{\beta}_r X_{ri})^2 + \lambda(1 - \hat{\beta}_1 - \hat{\beta}_r) \quad (3-50)$$

حال نسبت به ضرایب مشتق گرفته و برابر صفر قرار می‌دهیم:

$$\begin{aligned} \partial L / \partial \hat{\beta}_1 &= -2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_r X_{ri} - \hat{\beta}_r X_{ri}) = 0, \\ \partial L / \partial \hat{\beta}_r &= -2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_r X_{ri} - \hat{\beta}_r X_{ri}) X_{ri} - \lambda = 0, \\ \partial L / \partial \hat{\beta}_r &= -2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_r X_{ri} - \hat{\beta}_r X_{ri}) X_{ri} - \lambda = 0, \\ \partial L / \partial \lambda &= 1 - \hat{\beta}_1 - \hat{\beta}_r = 0. \end{aligned} \quad (3-51)$$

از معادله اول، $\hat{\beta}_1 = \bar{Y} - \hat{\beta}_r \bar{X}_r - \hat{\beta}_r \bar{X}$ به دست می‌آید. به جای $\hat{\beta}_1$ در معادله دوم و سوم قرار داده و نتایج را به صورت زیر ساده می‌کنیم:

$$\begin{aligned} \sum (Y_i - \hat{\beta}_r x_{ri} - \hat{\beta}_r x_{ri}) X_{ri} - \lambda &= 0, \\ \sum (Y_i - \hat{\beta}_r x_{ri} - \hat{\beta}_r x_{ri}) X_{ri} - \lambda &= 0, \end{aligned} \quad (3-52)$$

x_{ri} و x_{ri} بر حسب انحراف از میانگین هستند. حال اگر به جای $\hat{\beta}_r$ از $\hat{\beta}_r = 1 - \hat{\beta}_r$ در معادلات (3-52) قرار دهیم، خواهیم داشت:

$$\begin{aligned} \sum (y_i - \hat{\beta}_r (x_{ri} - x_{ri}) - x_{ri}) X_{ri} - \lambda &= 0, \\ \sum (y_i - \hat{\beta}_r (x_{ri} - x_{ri}) - x_{ri}) X_{ri} - \lambda &= 0. \end{aligned} \quad (3-53)$$

با حل معادلات فوق، $\hat{\beta}_r$ به دست می‌آید^۱:

$$\hat{\beta}_r = \frac{\sum (x_{ri} - x_{ri})(y_i - x_{ri})}{\sum (x_{ri} - x_{ri})^2} \quad (3-54)$$

و $\hat{\beta}_r$ نیز برابر است با:

$$\hat{\beta}_r = 1 - \hat{\beta}_r = \frac{\sum (x_{ri} - x_{ri})(y_i - x_{ri})}{\sum (x_{ri} - x_{ri})^2} \quad (3-55)$$

البته می‌توان به جای روش فوق، ابتدا از $\hat{\beta}_r = 1 - \hat{\beta}_r$ در معادله رگرسیون قرار داده و سپس ضرایب را برآورد نمود:

^۱ توجه شود که رابطه $\sum x_{ri} X_{ri} = \sum x_{ri} x_{ri}$ و $\sum x_{ri} X_{ri} = \sum x_{ri}^2$ برقرار است. مشابه این روابط برای سایر متغیرها نیز برقرار است.

$$\begin{aligned} Y_i &= \beta_1 + \beta_2 X_{vi} + (1 - \beta_2) X_{ri} + u_i \\ &= \beta_1 + \beta_2 (X_{vi} - X_{ri}) + X_{ri} + u_i \end{aligned}$$

$$Y_i - X_{ri} = \beta_1 + \beta_2 (X_{vi} - X_{ri}) + u_i \quad (3-56)$$

با تخمین معادله (۳-۵۶)، تخمین زننده β_1 و β_2 به دست می آید که مشابه قبل است. سپس β_2 نیز از $\beta_2 = 1 - \beta_1$ به دست می آید.

حال بحث فوق را در حالت کلی به کار می بریم. بدین منظور ابتدا رگرسیون و قیدها را به صورت ماتریسی می نویسیم:

$$\begin{aligned} y &= X\beta + u \\ R\beta &= r \end{aligned} \quad (3-57)$$

بردارهای y ، u و β و ماتریس X مشابه (۳-۲۹) می باشند. معادله دوم، قیدها را نشان می دهد.

به عنوان مثال می تواند بیانگر قید $\beta_1 + \beta_2 = 1$ باشد که به صورت $\begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} = 1$ [۱] نوشته می شود. به هر حال، R یک ماتریس $m \times K$ و r یک بردار $m \times 1$ است (m تعداد قیدها است). تخمین مقید از مسئله زیر به دست می آید:

$$\begin{aligned} \min \sum e_i^2 = e'e = (y - X\hat{\beta})'(y - X\hat{\beta}) &= y'y + \hat{\beta}'X'X\hat{\beta} - 2\hat{\beta}'X'y \\ \text{st. } R\hat{\beta} &= r \end{aligned} \quad (3-58)$$

با تشکیل تابع لاگرانژ و مشتق گیری نسبت به $\hat{\beta}$ و بردار ضرایب لاگرانژ (در اینجا λ بردار ستونی $m \times 1$ است) تخمین مقید ضرایب به دست می آید (ضرایب لاگرانژ را برابر با 2λ در نظر می گیریم):

$$L = y'y + \hat{\beta}'X'X\hat{\beta} - 2\hat{\beta}'X'y + 2\lambda'(r - R\hat{\beta}) \quad (3-59)$$

$$\partial L / \partial \hat{\beta} = 2X'X\hat{\beta} - 2X'y - 2R'\lambda = 0 \quad (3-60)$$

$$\partial L / \partial \lambda = -2(R\hat{\beta} - r) = 0 \quad (3-61)$$

با حل معادلات (۳-۶۰) و (۳-۶۱) تخمین مقید به دست می آید که آن را با $\hat{\beta}_R$ نشان می دهیم:

$$\hat{\beta}_R = \hat{\beta}_{UR} + (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(r - R\hat{\beta}_{UR}) \quad (3-62)$$

$\hat{\beta}_{UR} = (X'X)^{-1}X'y$ تخمین غیرمقید است.

امید ریاضی و واریانس $\hat{\beta}_R$ عبارت است از:

$$\begin{aligned} E(\hat{\beta}_R) &= \beta \\ \text{var}(\hat{\beta}_R) &= \sigma^2 (X'X)^{-1} - \sigma^2 (X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} R(X'X)^{-1} \end{aligned} \quad (3-63)$$

۳-۱۲ آزمون محدودیت‌ها

در برخی موارد علاوه بر آزمون معنی‌دار بودن ضرایب، لازم است آزمون‌های دیگری را در مورد ضرایب انجام دهیم. آزمون معنی‌دار بودن ضرایب که با t صورت می‌گیرد به معنی آزمون فرضیه $\beta_i = 0$ است. همچنین F که در تحلیل واریانس مورد استفاده قرار می‌گیرد برای آزمون فرضیه $\beta_1 = \beta_2 = \dots = \beta_K = 0$ می‌باشد که به معنی آزمون معنادار بودن کل معادله رگرسیون است. علاوه بر این می‌توان فرضیه‌های دیگری نیز برای ضرایب مطرح و آزمون نمود. به عنوان مثال فرضیه $\beta_i = a$ که a یک مقدار ثابت است. یا آزمون فرضیه $\beta_1 + \beta_2 = 1$ و یا هر فرضیه دیگری راجع به ضرایب را می‌توان آزمون نمود. برخی از این فرضیه‌ها یا محدودیت‌ها نسبتاً ساده هستند که می‌توان برای آزمون آنها از t استفاده نمود. به عنوان مثال می‌توان فرضیه $\beta_1 = 5$ را با استفاده از t آزمون نمود:

$$t = \frac{\hat{\beta}_1 - 5}{\sqrt{\text{var}(\hat{\beta}_1)}} \quad (3-64)$$

همچنین می‌توان فرضیه $\beta_1 = \beta_2$ را به صورت $\beta_1 - \beta_2 = 0$ نوشت و سپس آن را با آماره t آزمون نمود:

$$t = \frac{(\hat{\beta}_1 - \hat{\beta}_2) - 0}{\sqrt{\text{var}(\hat{\beta}_1 - \hat{\beta}_2)}} \quad (3-65)$$

$\text{var}(\hat{\beta}_1 - \hat{\beta}_2)$ برابر با $\text{var}(\hat{\beta}_1) + \text{var}(\hat{\beta}_2) - 2\text{cov}(\hat{\beta}_1, \hat{\beta}_2)$ است.

علاوه بر این، فرضیه $\beta_1 + \beta_2 = 1$ را می‌توان با استفاده از t به صورت زیر انجام داد:

$$t = \frac{(\hat{\beta}_1 + \hat{\beta}_2) - 1}{\sqrt{\text{var}(\hat{\beta}_1 + \hat{\beta}_2)}} \quad (3-66)$$

$\text{var}(\hat{\beta}_1 + \hat{\beta}_2)$ برابر با $\text{var}(\hat{\beta}_1) + \text{var}(\hat{\beta}_2) + 2\text{cov}(\hat{\beta}_1, \hat{\beta}_2)$ است.

روشن عمومی برای آزمون محدودیت‌ها را می‌توان بر اساس آماره F ارائه نمود. فرض کنید رگرسیون K متغیره زیر را داریم:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_K X_{Ki} + u_i \quad (3-67)$$

از بخش ۳-۵ به‌خاطر داریم که برای آزمون $\beta_1 = \beta_2 = \dots = \beta_K = 0$ از F تحت عنوان تحلیل واریانس استفاده نمودیم. حال می‌توان با استفاده از F هر فرضیه دیگری را که در رابطه با ضرایب باشد، آزمون نمود. بدین منظور مدل (۳-۶۷) را رگرسیون غیرمقید^۱ می‌نامیم؛ زیرا هیچ محدودیتی روی ضرایب آن اعمال نشده است. برای این مدل، ضریب تعیین را با R^2_{UR} و مجموع مجذور باقیمانده‌ها را با RSS_{UR} نشان می‌دهیم. حال می‌توان هر گونه محدودیتی را روی ضرایب اعمال کرده و سپس با در نظر گرفتن این محدودیت‌ها، مدل مذکور را مجدداً برآورد می‌کنیم که به آن رگرسیون مقید می‌گوییم. ضریب تعیین این مدل را با R^2_R و مجموع مجذور باقیمانده‌ها را با RSS_R نشان می‌دهیم. توجه داریم که $RSS_{UR} \leq RSS_R$ است؛ زیرا خطاهای رگرسیون مقید^۲، بیشتر از رگرسیون غیرمقید می‌باشد. اگر تفاضل $RSS_R - RSS_{UR}$ بزرگ باشد بدان معنا است که محدودیت‌های مورد نظر معنی‌دار هستند و در غیر این صورت، معنادار نیستند. در چنین شرایطی می‌توان از F استفاده نمود که بیانگر معنادار بودن یا معنادار نبودن محدودیت‌های مورد نظر می‌باشد. بدیهی است که اگر محدودیت‌های اعمال شده واقعاً معنادار باشند، رگرسیون‌های مقید و غیرمقید تفاوت قابل توجهی خواهند داشت و لذا تفاضل RSS ‌ها بزرگ می‌شود که موجب بزرگ شدن F شده و فرضیه H_0 (وجود محدودیت‌ها) رد می‌شود. در واقع بدان معنا است که این محدودیت‌ها، قدرت توضیح‌دهندگی مدل را به‌طرز محسوسی کاهش می‌دهند.

$$F = \frac{\frac{RSS_R - RSS_{UR}}{m}}{\frac{RSS_{UR}}{n-K}} = \frac{n-K}{m} \frac{RSS_R - RSS_{UR}}{RSS_{UR}} \quad (3-68)$$

که m تعداد محدودیت‌ها است. به‌عنوان مثال، $\beta_1 + \beta_2 = 1$ بیانگر وجود یک محدودیت است. اما فرضیه‌های $\beta_1 + \beta_2 = 1$ و $\beta_3 = \beta_4$ ، بیانگر وجود دو محدودیت است. همچنین آزمون فرضیه

^۱ Unrestricted

^۲ Restricted

$\beta_1 = \beta_2 = \beta_3 =$ بیانگر سه محدودیت است، زیرا سه محدودیت به صورت $\beta_4 = 1, \beta_5 = 0$ و $\beta_6 = 0$ داریم.

از آنجا که رابطه $R^2 = 1 - \frac{RSS}{TSS}$ برقرار است، لذا می توان F را بر حسب R^2 نوشت:

$$F = \frac{n-K}{m} \frac{R_{UR}^2 - R_R^2}{1 - R_{UR}^2} \quad (3-69)$$

به جای F می توان از χ^2 نیز استفاده نمود. از آنجا که $RSS = \sum e_i^2$ را می توان به صورت $\frac{RSS}{\sigma^2} = \sum \left(\frac{e_i - \bar{e}}{\sigma} \right)^2$ نوشت ($\bar{e} = 0$)، لذا عبارت $\frac{e_i - \bar{e}}{\sigma}$ توزیع نرمال استاندارد و مجذور آن توزیع χ^2 با درجه آزادی ۱ دارد. اما مجموع آن دارای توزیع χ^2 با درجه آزادی $n-K$ است. همچنین $\frac{RSS_R}{\sigma^2}$ و $\frac{RSS_{UR}}{\sigma^2}$ نیز توزیع χ^2 دارند که درجه آزادی اولی برابر با $n-(K-m)$ و دومی برابر با $n-K$ می باشد، زیرا در اولی فقط $K-m$ پارامتر و در دومی K پارامتر را برآورد می کنیم. تفاضل $\frac{RSS_R - RSS_{UR}}{\sigma^2}$ نیز توزیع χ^2 با درجه آزادی $[n-(K-m)] - (n-K) = m$ دارد. اگر مقدار χ_m^2 بزرگ باشد، مشابه با بزرگ بودن F است.^۱ در حالت کلی، برای آزمون محدودیت $R\beta = r$ نیز از نسبت F استفاده می کنیم.^۲ بدین منظور ابتدا خطاهای غیر مقید و مقید را حساب می کنیم:

$$e_{UR} = y - X\hat{\beta}_{UR} \quad (3-70)$$

$$e_R = y - X\hat{\beta}_R$$

خطاهای مقید را به صورت زیر می نویسیم:

$$\begin{aligned} e_R &= y - X\hat{\beta}_R = y - X\hat{\beta}_R + X\hat{\beta}_{UR} - X\hat{\beta}_{UR} \\ &= (y - X\hat{\beta}_{UR}) - X(\hat{\beta}_R - \hat{\beta}_{UR}) \\ &= e_{UR} - X(\hat{\beta}_R - \hat{\beta}_{UR}) \end{aligned} \quad (3-71)$$

حال مجموع مجذور خطاها (RSS) را حساب می کنیم:

^۱ این روش، معروف به آزمون والد است که جزئیات آن در فصل هفتم ارائه شده است.

^۲ سایر آزمون ها در فصل هفتم معرفی شده اند.

$$RSS_R = e'_R e_R = e'_{UR} e_{UR} + (\hat{\beta}_R - \hat{\beta}_{UR})' X' X (\hat{\beta}_R - \hat{\beta}_{UR}) \quad (3-72)$$

با استفاده از معادله فوق، تفاوت بین RSS های مقید و نامقید را به صورت زیر می‌نویسیم:

$$RSS_R - RSS_{UR} = e'_R e_R - e'_{UR} e_{UR} = (\hat{\beta}_R - \hat{\beta}_{UR})' X' X (\hat{\beta}_R - \hat{\beta}_{UR}) \quad (3-74)$$

از $\hat{\beta}_R = \hat{\beta}_{UR} + (X'X)^{-1} R' [R(X'X)^{-1} R']^{-1} (r - R\hat{\beta}_{UR})$ به جای $\hat{\beta}_R - \hat{\beta}_{UR}$ در (۳-۷۴) قرار می‌دهیم:

$$\begin{aligned} RSS_R - RSS_{UR} &= e'_R e_R - e'_{UR} e_{UR} = (\hat{\beta}_R - \hat{\beta}_{UR})' X' X (\hat{\beta}_R - \hat{\beta}_{UR}) \\ &= (r - R\hat{\beta}_{UR})' [R(X'X)^{-1} R']^{-1} (r - R\hat{\beta}_{UR}) \end{aligned} \quad (3-75)$$

حال برای آزمون فرضیه $H: R\beta = r$ نسبت F را مشابه (۳-۶۸) تشکیل می‌دهیم:

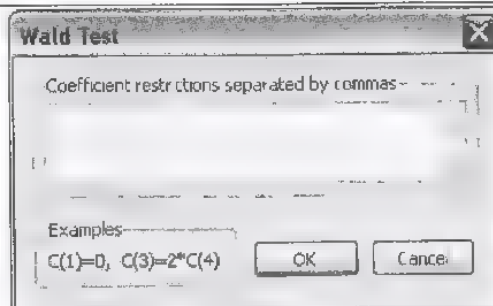
$$\begin{aligned} F_{m, n-K} &\equiv \frac{(RSS_R - RSS_{UR})/m}{RSS_{UR}/(n-K)} \\ &= \frac{n-K}{m} \frac{(e'_R e_R - e'_{UR} e_{UR})}{e'_{UR} e_{UR}} \\ &= \frac{n-K}{m} \frac{(\hat{\beta}_R - \hat{\beta}_{UR})' X' X (\hat{\beta}_R - \hat{\beta}_{UR})}{e'_{UR} e_{UR}} \\ &= \frac{n-K}{m} \frac{(r - R\hat{\beta}_{UR})' [R(X'X)^{-1} R']^{-1} (r - R\hat{\beta}_{UR})}{e'_{UR} e_{UR}} \end{aligned} \quad (3-76)$$

بنابراین، برای محاسبه F فقط لازم است که رگرسیون غیرمقید را برآورد کرده و F را حساب می‌کنیم. اگر واقعاً محدودیت‌هایی تأثیر باشند آنگاه به‌ازای تخمین‌های غیرمقید نیز برقرار خواهند بود و لذا $r - R\hat{\beta}$ به صفر نزدیک می‌شود که به دنبال آن مقدار F نیز کوچک شده و در ناحیه بحرانی قرار نمی‌گیرد و فرضیه H رد نمی‌شود. این بدان معنا است که محدودیت‌های $R\beta = r$ برقرار هستند.

آزمون محدودیت‌ها با Eviews: آزمون والد

فایل داده

در پنجره Equation (تایج تخمین)، برای آزمون محدودیت‌ها، از منوی View گزینه Coefficient diagnostics و سپس گزینه Wald Test-Coefficient Restrictions را انتخاب می‌کنیم. در این صورت پنجره‌ای به نام Wald Test می‌شود.



در این پنجره، محدودیتهای مورد نظر را وارد می‌کنیم. به عنوان مثال اگر محدودیتهای $\beta_1 + \beta_0 = 1$ ، $\beta_1 = 0$ و $\beta_1 = -\beta_2$ را داشته باشیم، آنها را به صورت زیر وارد می‌کنیم:

$$C(1)=1, C(3)=2*C(4) \text{ و } C(5)=1, C(3)=-C(4)$$

اگر در رگرسیون سرمایه‌گذاری، ضریب نرخ بهره را برابر صفر قرار دهیم، سپس در پنجره wald test عبارت $C(2)=0$ را نوشته و OK را انتخاب می‌کنیم. نتایج آزمون در پنجره زیر نشان داده می‌شود:

Equation: UNTITLED Workfile: DATA5: Untitled			
View	Proc	Object	Print Name Freeze Estimate Forecast Stats
Wald Test			
Equation: untitled			
Test Statistic	Value	df	Probability
t-statistic	-1.232988	31	0.2268
F statistic	1.520254	(1, 31)	0.2268
Chi-square	1.520254	1	0.2176
Null Hypothesis: C(2)=0			
Null Hypothesis Summary			
Normalized Restriction (-0)	Value	Std. Err	
C(2)	-246.7890	200.1556	
Restrictions are linear in coefficients			

در پنجره فوق، t-statistic بیانگر مقدار آماره t برای ضریب نرخ بهره در معادله اصلی (سرمایه‌گذاری) است (یعنی $C(2)$) که وضعیت معنادار بودن یا بودن آن نشان می‌دهد. چون مقدار F و χ^2 کوچک هستند (زیرا احتمال مربوطه بزرگتر از ۰/۰۵ است)، لذا محدودیت مورد نظر معنادار نیست و $C(2)=0$ برابر با صفر است. حال اگر هم زمان محدودیت $C(2)=0$ و $C(1)=0$ را اعمال نماییم (یعنی عرض از مبدأ و ضریب نرخ بهره را برابر صفر قرار دهیم) نتایج آزمون واند به صورت زیر می‌باشد:

Equation: UNTITLED Workfile: DATA5:Untitled			
View	Proc	Object	Print Name Freeze Estimate Forecast Stats
Wald Test Equation: UNTITLED			
Test Statistic	Value	df	Probability
F-statistic	3.127557	(2, 31)	0.0579
Chi-square	6.255115	2	0.0438
Null Hypothesis: C(1)=0 C(2)=0 Null Hypothesis Summary			
Normalized Restriction (= 0)	Value	Std. Err	
C(1)	5742.205	5095.942	
C(2)	-245.7890	200.1556	
Restrictions are linear in coefficients			

در اینجا مقدار F و χ^2 بزرگ هستند (زیرا سطح احتمال مربوطه نزدیک به ۰/۰۵ و یا کوچکتر هستند) و لذا محدودیت‌های مورد نظر، معنادار هستند. مقدار آماره والد برابر با $\chi^2 = 6/25$ است. جزئیات آماره والد در فصل هفتم بحث شده است.

۳-۱۳ پیش‌بینی با رگرسیون چندمتغیره

در فصل دوم مبحث پیش‌بینی را براساس رگرسیون دو متغیره بررسی کردیم. در اینجا نیز بحث مشابهی را برای رگرسیون K متغیره می‌توان مطرح کرد. بدین منظور معادله چندمتغیره را در نظر بگیرید آن را به صورت زیر می‌نویسیم:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_K X_{Kt} + u_t$$

$$= [1 \quad X_{1t} \quad \dots \quad X_{Kt}] \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_K \end{bmatrix} + u_t = \mathbf{x}_t' \boldsymbol{\beta} + u_t \quad (3-77)$$

$$\mathbf{x}_t' = [1 \quad X_{1t} \quad \dots \quad X_{Kt}]$$

مقدار پیش‌بینی Y برای سال f برابر است با:

$$Y_f = \mathbf{x}_f' \boldsymbol{\beta} + u_f \quad (3-78)$$

مقدار تخمینی این پیش‌بینی برابر است با:

$$\hat{Y}_f = \mathbf{x}_f' \hat{\boldsymbol{\beta}} \quad (3-79)$$

خطای پیش‌بینی برابر با تفاوت مقدار واقعی و پیش‌بینی Y در سال f می‌باشد:

$$e_f = Y_f - \hat{Y}_f = \mathbf{x}_f' \boldsymbol{\beta} + u_f - \mathbf{x}_f' \hat{\boldsymbol{\beta}}$$

$$= -\mathbf{x}_f' (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) + u_f \quad (3-80)$$

e_f یک متغیر تصادفی است که امید ریاضی آن برابر صفر است و واریانس آن برابر است با:

$$\begin{aligned}\text{var}(e_f) &= E(e_f^2) = E[-\mathbf{x}'_f(\hat{\beta} - \beta) + u_f][-\mathbf{x}'_f(\hat{\beta} - \beta) + u_f] \\ &= E[\mathbf{x}'_f(\hat{\beta} - \beta)(\hat{\beta} - \beta)' \mathbf{x}_f] + E(u_f^2) \\ &= \mathbf{x}'_f \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f + \sigma^2 = \sigma^2 [1 + \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f]\end{aligned}\quad (3-81)$$

توجه شود که $E[\mathbf{x}'_f(\hat{\beta} - \beta)u_f] = \mathbf{x}'_f E(\hat{\beta} - \beta)E(u_f) = 0$ است زیرا $\hat{\beta}$ تابعی از u_t است که $t < f$ می باشد و به دلیل عدم خودهمبستگی بین u_t و u_f ، می توان نتیجه گرفت $\hat{\beta}$ و u_f مستقل هستند.

با توجه به واریانس خطای پیش بینی می توان انحراف معیار خطای پیش بینی را حساب کرد که برابر با $SE(e_f) = \sqrt{\text{var}(e_f)}$ می باشد. مرز پیش بینی برابر با «به اضافه و منهای دو برابر انحراف معیار پیش بینی» می باشد. پیش بینی با مدل های چندمتغیره با استفاده از Eviews دقیقاً مشابه پیش بینی با رگرسیون یک متغیره است.

فاصله اطمینان پیش بینی برای مقدار پیش بینی (Y_f) عبارت است از:

$$\begin{aligned}t_{n-K} = \frac{e_f}{\sqrt{\text{var}(e_f)}} &\Rightarrow t_{n-K} = \frac{Y_f - \hat{Y}_f}{\hat{\sigma} \sqrt{1 + \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f}} \\ \Rightarrow \left(\hat{Y}_f - t_{\alpha/2, n-K} \hat{\sigma} \sqrt{1 + \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f} \leq Y_f \leq \hat{Y}_f + t_{\alpha/2, n-K} \hat{\sigma} \sqrt{1 + \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f} \right) &\quad (3-82)\end{aligned}$$

تعیین فاصله اطمینان پیش بینی برای امید ریاضی شرطی، یعنی $E(Y_t | X_t) = \mathbf{x}'_t \beta$ نیز مشابه بحث فوق می باشد. با توجه به اینکه برآورد امید ریاضی شرطی برابر با $\hat{Y}_t = \mathbf{x}'_t \hat{\beta}$ است لذا خطای پیش بینی برابر است با:

$$e_f^* = E(Y_f | X_f) - \hat{Y}_f = \mathbf{x}'_f \beta - \mathbf{x}'_f \hat{\beta} = -\mathbf{x}'_f (\hat{\beta} - \beta) \quad (3-83)$$

امید ریاضی و واریانس e_f^* برابر است با:

$$\begin{aligned}E(e_f^*) &= 0 \\ \text{var}(e_f^*) &= E(e_f^* e_f^*) = E\left[\mathbf{x}'_f (\hat{\beta} - \beta)(\hat{\beta} - \beta)' \mathbf{x}_f\right] \\ &= \mathbf{x}'_f E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'] \mathbf{x}_f = \sigma^2 \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f\end{aligned}\quad (3-84)$$

پیش‌بینی فاصله‌ای برای معادله رگرسیون یا امید ریاضی شرطی به صورت زیر به دست می‌آید:

$$t_{n-K} = \frac{e_f^*}{\sqrt{\text{var}(e_f^*)}} = \frac{E(Y_f | X_f) - \hat{Y}_f}{\hat{\sigma} \sqrt{\mathbf{x}_f' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f}}$$

$$\rightarrow \left(\hat{Y}_f - t_{\alpha/2, n-K} \hat{\sigma} \sqrt{\mathbf{x}_f' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f} \leq E(Y_f | X_f) \leq \hat{Y}_f + t_{\alpha/2, n-K} \hat{\sigma} \sqrt{\mathbf{x}_f' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f} \right) \quad (3-85)$$

مسائل

۱- برای برآورد رگرسیون $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + u_i$ مقادیر زیر بر حسب انحراف از میانگین از نمونه‌ای به حجم $n = 24$ حساب شده‌اند:

$$\sum y_i^2 = 60, \quad \sum x_{i1}^2 = 10, \quad \sum x_{i2}^2 = 30, \quad \sum x_{i3}^2 = 20.$$

$$\sum x_{i1} y_i = 7, \quad \sum x_{i2} y_i = -7, \quad \sum x_{i3} y_i = -26$$

$$\sum x_{i1} x_{i2} = 10, \quad \sum x_{i1} x_{i3} = 5, \quad \sum x_{i2} x_{i3} = 15$$

الف) فرضیه $\beta_0 + \beta_1 + \beta_2 = 1$ را آزمون کنید.

ب) فرضیه $[\beta_0 \ \beta_1 \ \beta_2] = [1 \ 1 \ 2]$ را آزمون کنید.

ج) فرضیه‌های الف و ب چه تفاوتی دارند.

۲- مقادیر زیر از یک نمونه ۲۰ تایی به دست آمده است.

$$\sum Y_i = 20, \quad \sum X_{i1} = 30, \quad \sum X_{i2} = 40$$

$$\sum Y_i^2 = 80, \quad \sum X_{i1}^2 = 90, \quad \sum X_{i2}^2 = 150$$

$$\sum X_{i1} Y_i = 60, \quad \sum X_{i2} Y_i = 90, \quad \sum X_{i1} X_{i2} = 120$$

الف) مقادیر فوق را ابتدا بر حسب انحراف از میانگین به دست آورید.

ب) رگرسیون Y روی X_1 و X_2 را برآورد کنید و آماره t را برای هر یک از ضرایب حساب کنید.

ج) R^2 و F را حساب کنید.

د) فرضیه برابری ضرایب X_1 و X_2 را آزمون کنید.

۳- تابع تولید از نمونه‌ای به حجم n ، به صورت زیر برآورد شده است:

$$\ln Q_i = 1/5 + .655 \ln K_i + .405 \ln L_i \quad R^2 = .95$$

$$(1/2) \quad (3/2) \quad (2/5)$$

کوواریانس ضریب سرمایه و نیروی کار برابر با ۰/۰۵ است.

الف) آیا کشش تولیدی سرمایه و کار یکسان هستند؟

ب) آیا بازدهی ثابت نسبت به مقیاس وجود دارد؟

۳- ثابت کنید که $\hat{\beta} = X(X'X)^{-1}X'y$ است.

۴- ثابت کنید که R^2 مجذور ضریب همبستگی ساده بین y و \hat{y} است (که

$$\hat{y} = X(X'X)^{-1}X'y \text{ می باشد}).$$

۵- فرق R^2 با \bar{R}^2 تعدیل شده چیست؟

۶- مدل رگرسیون زیر به صورت انحراف از میانگین می باشد:

$$y_i = \beta_0 x_{0i} + \beta_1 x_{1i} + u_i$$

مقادیر زیر حساب شده اند:

$$\begin{aligned} \sum y_i^2 &= 500 & \sum x_{0i}^2 &= 30 & \sum x_{1i}^2 &= 20 & n &= 20 \\ \sum x_{0i} y_i &= 30 & \sum x_{1i} y_i &= 20 & \sum \sum x_{0i} x_{1i} &= 0 \end{aligned}$$

الف) ضرایب β_0 ، β_1 و R^2 را برآورد کنید.

ب) فرضیه $\beta_0 = 0$ را آزمون کنید.

ج) فرضیه $\beta_1 = \beta_0 = 0$ را آزمون کنید.

د) فرضیه $\beta_1 = 3\beta_0$ را آزمون کنید.

۷- ثابت کنید که مجموع مجذورات پسماندهای (باقیمانده‌های) مقید بزرگتر از مجموع مجذورات غیرمقید است؟

۸- تابع تولید زیر را در نظر بگیرید:

$$Q_i = AL_i^{\beta_1} L_{1i}^{\beta_2} K_i^{\beta_3} e^{u_i}$$

L_i تعداد کارگران ماهر، L_{1i} تعداد کارگران غیرماهر، K_i سرمایه و u_i جمله اختلال است. در

صورتی که همواره رابطه $L_1 + L_2 = 1000$ برقرار باشد آیا می توان تابع تولید را برآورد کرد؟

۹- در مسئله ۱ فصل اول، رگرسیون $Y_i = \beta_0 + \beta_1 X_i + \beta_2 Z_i + u_i$ برآورد کنید.

۱۰- در مسئله ۳ اثر خالص و ناخالص X بر Y را حساب کنید.

۱۱- در مسئله ۱ فصل اول، ضرایب همبستگی جزئی را محاسبه و تحلیل کرده و با ضرایب

همبستگی ساده مقایسه کنید.

۱۲- معادله زیر برآورد شده است:

$$\hat{Y}_i = 2/5 + 0/42X_{1i} + 1/2X_{2i} \quad R^2 = 0/75$$

آزمون معنی دار بودن رگرسیون را انجام دهید.

۱۳- مقادیر زیر برای یک رگرسیون دو متغیره حساب شده اند:

$$X'X = \begin{bmatrix} 33 & 0 & 0 \\ 0 & 40 & 20 \\ 0 & 20 & 60 \end{bmatrix} \quad X'y = \begin{bmatrix} 132 \\ 24 \\ 42 \end{bmatrix} \quad \sum y_i^2 = 150$$

الف) حجم نمونه چقدر است؟

ب) ضرایب معادله رگرسیون را تخمین یزنید.

ج) σ^2 را حساب کنید.

د) R^2 و \bar{R}^2 را حساب کنید.

هـ) آماره t را برای هر یک از ضرایب حساب کنید.

و) آزمون معنی دار بودن رگرسیون را انجام دهید.

۱۴- در معادله $Y_i = \sum_{j=1}^K \beta_j X_{ji} + u_i$ که شکل ماتریسی آن به صورت $y = X\beta + u$ است، با

نمونه‌ای به حجم n ، تخمین $\hat{\beta}$ به صورت زیر است:

$$\hat{\beta}^n = (X'X)^{-1} X'y$$

حال اگر یک مشاهده به n مشاهده قبلی اضافه کنیم، ثابت کنید که تخمین جدید β که با

$\hat{\beta}^{n+1}$ نشان می‌دهیم به صورت زیر است:

$$\hat{\beta}^{n+1} = \hat{\beta}^n + \frac{(X'X)^{-1} z'_{n+1} (Y_{n+1} - z_{n+1}' \hat{\beta}^n)}{1 + z_{n+1}' (X'X)^{-1} z_{n+1}}$$

$$X = \begin{bmatrix} 1 & X_{11} & \dots & X_{K1} \\ 1 & X_{12} & \dots & X_{K2} \\ \vdots & \vdots & & \vdots \\ 1 & X_{1n} & \dots & X_{Kn} \end{bmatrix}$$

$$z_{n+1} = [1 \quad X_{1(n+1)} \quad \dots \quad X_{K(n+1)}]$$

۱۵- در مسئله ۱۴ ثابت کنید که رابطه زیر برقرار است:

$$RSS_{n+1} = RSS_n + \frac{(Y_{n+1} - \mathbf{z}_{n+1}'\hat{\beta}^n)^2}{1 + \mathbf{z}_{n+1}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{z}_{n+1}}$$

۱۶- در رگرسیون $Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \beta_4 X_{3t} + \beta_5 X_{4t} + u_t$ ، مراحل آزمون فرضیه $\beta_1 = \beta_2 = 0$ را توضیح داده و آماره F را تشکیل دهید.

۱۷- در معادله $Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + u_t$ کوواریانس $\hat{\beta}_2$ و $\hat{\beta}_3$ را حساب کنید. آیا امکان دارد که کوواریانس آنها برابر صفر شود.

۱۸- ثابت کنید که در رگرسیون $Y_t = \beta_1 + \beta_2 X_{1t} + \dots + \beta_K X_{Kt} + u_t$ ، تغییرات توضیح داده شده برابر است با:

$$ESS = \hat{\beta}_1 \sum x_{1t} y_t + \hat{\beta}_2 \sum x_{2t} y_t + \dots + \hat{\beta}_K \sum x_{Kt} y_t$$

۱۹- معادله $Y_t = \beta_1 + \beta_2 X_{1t} + \dots + \beta_K X_{Kt} + u_t$ را به صورت $y_t = \beta_2 x_{2t} + \dots + \beta_K x_{Kt} + u_t$ بنویسید. حروف کوچک بیانگر انحراف از میانگین هستند.
۲۰- رگرسیون‌های زیر برآورد شده‌اند:

$$\hat{Y}_t = \hat{\alpha}_1 + 0.95 X_{1t}$$

$$\hat{Y}_t = \hat{\alpha}_2 + 0.85 X_{2t}$$

$$\hat{X}_{2t} = \hat{\alpha}_3 + 0.75 X_{1t}$$

$$\hat{X}_{1t} = \hat{\alpha}_4 + 0.65 X_{2t}$$

بر اساس اطلاعات فوق، ضرایب β_2 و β_3 را در معادله $Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + u_t$ برآورد کنید.

۲۱- رگرسیون $Y_t = \alpha + \beta Y_t^* + u_t$ را داریم که Y_t مقدار واقعی و Y_t^* مقدار پیش‌بینی می‌باشد. فرضیه انتظارات عقلایی ادعا می‌کند که شکل‌گیری انتظارات به‌طور متوسط درست است، زیرا خطای پیش‌بینی دارای میانگین صفر می‌باشد ($E(Y_t) = E(Y_t^*)$ است). نتایج حاصل از برآورد مدل فوق عبارت است از:

$$Y_t = 0.25 + 0.95 Y_t^* \quad RSS = 25/4, \quad n = 32$$

$$(0/2) \quad (6/6)$$

اگر $\bar{Y}^* = 10$ ، $\sum (Y_t^* - \bar{Y}^*)^2 = 40/85$ باشد، آیا می‌توان نتایج فوق را مطابق با فرضیه انتظارات عقلایی دانست؟

۲۲- در رگرسیون $Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + u_i$ آیا درست است که آزمون

فرضیه $H_0: \beta_1 = \dots = \beta_K = 0$ را معادل به فرضیه $H_1: R^2 = 0$ بدانیم؟ چرا؟

۲۳- اگر در رگرسیون $Y_i^* = \beta_1 + \beta_2 X_{2i}^* + \beta_3 X_{3i}^* + u_i$ متغیرها استاندارد شده باشند، ثابت کنید

که روابط زیر برقرار است (ضریب همبستگی بین متغیرها را نشان می‌دهد: ۱ برای Y ، ۲ برای X_2 و ۳ برای X_3)

$$\mathbf{X}'\mathbf{X} = n \begin{bmatrix} 1 & r_{12} \\ r_{12} & 1 \end{bmatrix} \quad (\text{الف})$$

$$\mathbf{X}'\mathbf{y} = n \begin{bmatrix} r_{12} \\ r_{13} \end{bmatrix} \quad (\text{ب})$$

$$\hat{\beta}_1 = 0 \quad (\text{ج})$$

$$\hat{\beta}_2 = \frac{r_{12} - r_{13}r_{23}}{1 - r_{23}^2}, \quad \hat{\beta}_3 = \frac{r_{13} - r_{12}r_{23}}{1 - r_{23}^2} \quad (\text{د})$$

۲۴- ثابت کنید که اگر به جای معادله $Y_i = \alpha_1 + \alpha_2 X_{2i} + u_i$ متغیر X_{2i} را اضافه کنیم، اولاً R^2

افزایش می‌یابد و ثانیاً در صورتی \bar{R}^2 افزایش می‌یابد که آماره t برای ضریب X_{2i} بزرگتر از ۱ باشد.

۲۵- رگرسیون $Y_i = \beta_1 + \beta_2 X_{2i} + u_i$ را داریم. باقیمانده‌های این مدل را با e_i و مقادیر

برآوردی را با \hat{Y}_i نشان می‌دهیم.

الف) در رگرسیون $e_i = \alpha_1 + \alpha_2 X_{2i} + \varepsilon_i$ ضریب تعیین (R^2) چه چیزی را بیان می‌کند. ثابت

کنید که nR^2 برابر با آماره ضریب لاگرانژ است.

ب) حاصل از رگرسیون $Y_i = \gamma_1 + \gamma_2 \hat{Y}_i + v_i$ چه چیزی را نشان می‌دهد و چه رابطه‌ای با

R^2 در معادله $Y_i = \beta_1 + \beta_2 X_{2i} + u_i$ دارد.

ج) در رگرسیون $Y_i = a_1 + a_2 e_i + w_i$ ضرایب a_1 و a_2 را برآورد کنید. R^2 این معادله چه

تفسیری دارد؟

۲۶- رگرسیون $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$ را در نظر بگیرید. حال رگرسیون‌های زیر نیز

برآورد شده‌اند:

$$X_{it} = \alpha_1 + \alpha_2 X_{it} + v_{it}$$

$$X_{it} = \gamma_1 + \gamma_2 X_{it} + v_{it}$$

یا استفاده از باقیمانده‌های معادلات فوق، معادله زیر را برآورد می‌کنیم:

$$\hat{v}_{it} = b_1 + b_2 \hat{v}_{it} + \varepsilon_i$$

الف) ثابت کنید که $\hat{b}_2 = \hat{\beta}_2$ است.

ب) اگر رگرسیون $Y_i = \gamma_1 + \gamma_2 \hat{v}_{it} + \gamma_3 \hat{v}_{it} + u_i$ را برآورد کنیم؛ رابطه بین $\hat{\beta}_2$ و $\hat{\beta}_3$ را به دست آورید.

ضمیمه فصل ۳: رگرسیون چند متغیره در Stata

فایل data3

برآورد معادلات رگرسیون چند متغیره در Stata

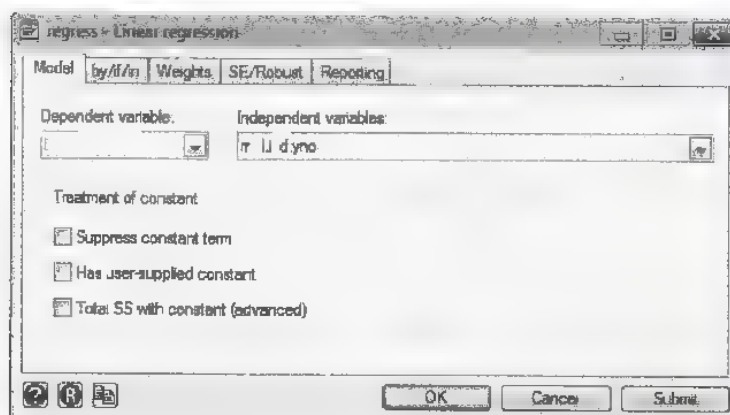
برآورد رگرسیون چند متغیره، مشابه رگرسیون ساده است. بدین منظور معادله زیر را در نظر بگیرید:

$$I_{it} = \alpha + \beta RRR_{it} + \theta \Delta YNO_{it} + \gamma I_{it-1}$$

میتوان برای وارد کردن تفاضل ΔYNO از d.yno و برای وقفه I_{it-1} از l.i استفاده می‌شود. بنابراین با انتخاب مسیر زیر مشابه رگرسیون چند متغیره می‌کنیم:

Linear regression → Linear models and related → Statistics

مسیرها را به صورت زیر وارد می‌کنیم:



نتایج به صورت زیر به دست می‌آید که کاملاً مشابه رگرسیون ساده است:

Results						
- preserve regress rr 1.1 d.yno						
Source	SS	df	MS			
Model	4.1221e+10	3	1.3740e+10	Number of obs =	35	
Residual	2.3058e+09	31	74380117.7	F(3, 31) =	184.73	
Total	4.3527e+10	34	1.2802e+09	Prob > F =	0.0000	
				R-squared =	0.9470	
				Adj R-squared =	0.9419	
				Root MSE =	8624.4	
	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
rr	-246.8273	200.1467	-1.23	0.227	-655.0293	161.3746
l1.	.8194636	.0523257	15.66	0.000	.7127447	.9261825
yno	1.18792	.1583372	7.50	0.000	.8649894	1.510851
_cons	5742.107	5095.64	1.13	0.268	-4650.52	16134.73

آزمون محدودیت‌ها (آزمون والد) در Stata

الف) آزمون محدودیت‌های صفری:

می‌خواهیم به‌طور همزمان صفر بودن چند ضریب را آزمون کنیم. مثلاً صفر بودن ضریب π و ΔYNO .بدین منظور، پس از برآورد معادله مورد نظر (در اینجا از معادله $I_t = \alpha + \beta RR_t + \theta \Delta YNO_t + \lambda_{t-1}$ استفاده کرده‌ایم)، فرمان زیر را اجرا می‌کنیم:

test (pi=0) (l.yno=0)

این فرضیه معادل با $\beta = \theta = 0$ است که می‌توان از آزمون F برای مقایسه دو مدل مقید و غیر مقید استفاده نمود:

$$I_t = \alpha + \beta RR_t + \theta \Delta YNO_t + \lambda_{t-1} \quad \text{مدل غیر مقید}$$

$$I_t = \alpha + \lambda_{t-1} \quad \text{مدل مقید}$$

نتیجه آزمون عبارت است از:

. test (rr=0) (d.yno=0)

```
( 1)  rr = 0
( 2)  d.yno = 0
```

```
F( 2, 31) = 31.83
Prob > F = 0.0000
```

چون مقدار $F = 31.83$ در ناحیه بحرانی قرار دارد (زیرا مقدار احتمال کوچکتر از ۰/۰۵ است)، لذا فرضیه H_0 (وجود محدودیت‌ها) رد می‌شود.

ب) آزمون محدودیت‌های خطی:

به عنوان مثال، محدودیت $\theta - 2\gamma = 0$ و $\beta + \theta = 120$ را در نظر بگیرید.

معادله مورد نظر را تخمین می‌زنیم و سپس فرمان زیر را اجرا می‌کنیم:

```
test (d.yno-2*l.i==0) (0.01*rr+d.yno==120)
```

نتیجه آزمون عبارت است از:

```
. test (d.yno-2*l.i==0) (0.01*rr+d.yno==120)
```

```
( 1)  d.yno - 2 l.i = 0
( 2)  .01 rr + d.yno = 120
```

```
F( 2, 31) = 2082.10
Prob > F = 0.0000
```

چون مقدار $F=2082.10$ در ناحیه بحرانی قرار دارد لذا فرضیه H_0 مبنی بر برقرار بودن این محدودیت‌ها رد می‌شود.

ج) آزمون محدودیت‌های غیر خطی

این آزمون نیز مشابه آزمون محدودیت‌های خطی است با این تفاوت که بایستی آن را به شکل دیگری وارد نماییم. به عنوان مثال

مدل $Y_t = \alpha + \beta X_t + \beta\gamma X_{t-1} + \gamma Y_{t-1} + u_t$ را در نظر بگیرید. این مدل ضریب X_{t-1} برابر با حاصل ضرب ضرایب X_t

و Y_{t-1} است. برای انجام این آزمون ابتدا معادله را به صورت زیر برآورد می‌کنیم:

```
reg y x l.x l.y
```

حال قید مورد نظر را با فرمان زیر آزمون می‌کنیم:

```
testnl _b[x]*_b[l.y]=_b[l.x]
```

بر اساس مقدار F در خصوص معنی‌دار بودن قیدها تصمیم‌گیری می‌کنیم.

تخمین رگرسیون مقید

برای برآورد رگرسیون مقید، ابتدا هر یک از قیدها را تعریف کرده و سپس رگرسیون مقید را برآورد می‌کنیم. به عنوان مثال می‌خواهیم

رگرسیون $I_t = \alpha + \beta RR_t + \theta \Delta YNO_t + \gamma I_{t-1} + u_t$ با توجه به قید $\theta - \gamma = 0$ برآورد کنیم. ابتدا قید را به صورت زیر تعریف می‌کنیم (قید شماره ۱):

```
constraint 1 d.yno-2*l.i=0
```

حال رگرسیون مقید را با فرمان `cnsreg` برآورد می‌کنیم:

```
cnsreg i rr d.yno l.i, c(1)
```

نتیجه تخمین مقید عبارت است از:

فرمان رگرسیون مقید

قید شماره ۱

```
. cnsreg i rr d.yno l.i, c(1)
```

constrained linear regression

(1) $d.yno - 2 \cdot l.i = 0$

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
rr	-355.4319	203.2331	-1.75	0.090	-769.4042 58.54047
yno	1.481907	.0766643	19.33	0.000	1.325747 1.638067
l.i	.7409533	.0383321	19.33	0.000	.6628733 .8190333
_cons	8901.894	5116.793	1.74	0.092	-1520.672 19324.46

Number of obs = 35
F(2, 32) = 248.68
Prob > F = 0.0000
Root MSE = 9067.8

$1/4819 = 2 \times 0.74095$

اگر دو قید به صورت $\theta - 2\gamma = 0$ و $\beta + \theta = 25$ داشته باشیم، ابتدا هر یک از قیدها را جداگانه با شماره‌های ۱ و ۲ به صورت زیر تعریف می‌کنیم:

constraint 1 $d.yno - 2 \cdot l.i = 0$

constraint 2 $0.01 \cdot rr + d.yno = 25$

حال رگرسیون مقید را با فرمان زیر برآورد می‌کنیم:

cnsreg i rr d.yno l.i, c(1 2)

فرمان رگرسیون مقید

قید شماره ۱

قید شماره ۲

```
. cnsreg i rr d.yno l.i, c(1 2)
```

constrained linear regression

(1) $d.yno - 2 \cdot l.i = 0$
(2) $.01 \cdot rr + d.yno = 25$

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
rr	2407.991	16.56588	145.36	0.000	2374.288 2441.695
yno	.920087	.1656588	5.55	0.000	.5830516 1.257122
l.i	.4600435	.0828294	5.55	0.000	.2915258 .6285611
_cons	55063.65	9822.637	5.61	0.000	35079.34 75047.96

Number of obs = 35
Root MSE = 23257

$0.01 \times 2407.991 / 99 = 0.920087$

$0.920087 = 2 \times 0.4600435$

نقض فروض کلاسیک


۱-۴ مقدمه

در فصل دوم فروض کلاسیک را مطرح کردیم که مبنای اصلی برآورد معادلات رگرسیون است. همان‌طور که دیدیم تمام نتایج و تحلیل‌های مربوط به تخمین معادلات، عمدتاً بر مبنای این فروض قرار دارد. در این راستا با چند مسئله مواجه‌ایم. اولاً چگونه می‌توان نقض فروض کلاسیک را تشخیص داد. ثانیاً در عمل چه چیزی باعث نقض فروض کلاسیک می‌شود. ثالثاً وقتی بدون توجه به نقض فروض کلاسیک، به تخمین معادلات و تفسیر نتایج می‌پردازیم با چه مسائل و مشکلاتی مواجه می‌شویم.

۲-۴ فرض اول: صفر بودن میانگین خطا

اولین فرض کلاسیک این است که امید ریاضی u_i برابر با صفر است. از آنجا که $e_i = Y_i - \hat{Y}_i$ است، لذا وقتی میانگین خطا صفر باشد بدان معنا است که مقدار تخمینی به‌طور متوسط برابر با مقدار واقعی است و در نتیجه، خطای متوسط یا امید ریاضی خطا برابر صفر خواهد بود. می‌توان ثابت کرد که اگر $E(u_i)$ برابر با مقدار ثابتی باشد، آنگاه شیب معادله رگرسیون بدون تورش، ولی برآورد عرض از مبدأ با تورش خواهد بود. اگر $E(u_i)$ ثابت نباشد، آنگاه برآورد شیب معادله رگرسیون نیز دچار تورش خواهد شد.

از طرف دیگر اگر معادله رگرسیون دارای عرض از مبدأ باشد، فرض $E(u_i) = 0$ نقض نمی‌شود. اما اگر رگرسیون فاقد عرض از مبدأ باشد، مقدار متوسط خطاها الزاماً صفر نخواهد شد و دارای آثار نامطلوبی خواهد بود؛ اولاً R^2 که برابر با نسبت ESS/TSS است ممکن است منفی شود. این موضوع بدین معنی است که متوسط نمونه (\bar{Y}) می‌تواند تغییرات Y را بهتر از متغیرهای توضیحی، توضیح دهد. به عبارت دیگر \bar{Y} به عنوان برآوردی از Y ، بهتر از معادله رگرسیون می‌باشد.^۱ ثانیاً، وقتی معادله رگرسیون فاقد عرض از مبدأ باشد می‌تواند به‌طور بالقوه منجر به تورش شدید در تخمین شیب معادله شود. بدین منظور نمودار (۴-۱) را در نظر بگیرید.



نمودار ۴-۱: حذف عرض از مبدأ و تأثیر آن بر شیب

خط OA بدون عرض از مبدأ و خط BB' با عرض از مبدأ می‌باشد. تصور کنید که خط رگرسیون صحیح توسط خط BB' توصیف شود. در این صورت اگر جمله ثابت حذف شود، تخمین شیب که با OA نشان داده شده است، دارای تورش خواهد بود.

در رگرسیون فاقد عرض از مبدأ، خطا برابر با $e_i = Y_i - \hat{Y}_i = Y_i - \hat{\beta}X_i$ است. از حداقل شدن مجموع مجذور خطاها خواهیم داشت:

$$\sum e_i^2 = \sum (Y_i - \hat{\beta}X_i)^2 \quad (4-1)$$

^۱ توجه شود که در رگرسیون $Y_i = \alpha + u_i$ برآورد α برابر با \bar{Y} است. در این معادله، $R^2 = 0$ است. حال اگر در رگرسیون $Y_i = \beta X_i + u_i$ مقدار R^2 منفی باشد، بدان معنا است که $\hat{Y}_i = \hat{\alpha} = \bar{Y}$ بهتر از $\hat{Y}_i = \hat{\beta}X_i$ می‌باشد.

$$\frac{\partial e_i^2}{\partial \beta} = -2 \sum (Y_i - \hat{\beta} X_i) X_i = 0 \Rightarrow \sum (Y_i - \hat{\beta} X_i) X_i = 0 \Rightarrow \sum e_i X_i = 0 \quad (4-2)$$

با حل (4-2) تخمین β به دست می آید:

$$\hat{\beta}^* = \frac{\sum X_i Y_i}{\sum X_i^2} \quad (4-3)$$

لذا در اینجا از شرط $\sum e_i X_i = 0$ استفاده شده است، اما شرط $\sum e_i = 0$ که برای تخمین α به کار می رفت، مورد استفاده قرار نمی گیرد. لذا ممکن است شرط $\sum e_i = 0$ برقرار نباشد و بدان معنا است که میانگین خطاها، صفر نخواهد شد. اگر شرط $\sum e_i = 0$ را به کار ببریم، آنگاه تخمین β به صورت زیر خواهد شد:

$$\sum e_i = 0 \Rightarrow \sum Y_i - \hat{\beta}^{**} \sum X_i = 0 \Rightarrow \bar{Y} = \hat{\beta}^{**} \bar{X} \Rightarrow \hat{\beta}^{**} = \frac{\bar{Y}}{\bar{X}} \quad (4-4)$$

بنابراین، تخمین دیگری برای شیب معادله رگرسیون به دست می آید که با $\hat{\beta}^*$ متفاوت است. بدین معنا که $\hat{\beta}^*$ مجموع مجذور خطاها یعنی $\sum e_i^2 = \sum (Y_i - \hat{\beta} X_i^2)$ را حداقل می کند که معادل با شرط $\sum e_i X_i = 0$ است، در حالی که $\hat{\beta}^{**}$ مجموع خطاها را صفر می کند که معادل با شرط $\sum e_i = 0$ است.

می توان نشان داد که وقتی عرض از مبدأ را از مدل صحیح یعنی $Y_i = \alpha + \beta X_i + u_i$ حذف می کنیم و به جای آن از مدل $Y_i = \beta X_i + v_i$ استفاده می کنیم، باعث می شود که تخمین شیب (یعنی $\hat{\beta}^*$) دچار تورش شود:

$$\begin{aligned} \hat{\beta}^* &= \frac{\sum X_i Y_i}{\sum X_i^2} = \frac{\sum X_i (\alpha + \beta X_i + u_i)}{\sum X_i^2} = \alpha \frac{\sum X_i}{\sum X_i^2} + \beta + \frac{\sum X_i u_i}{\sum X_i^2} \\ E(\hat{\beta}^*) &= \alpha \frac{\sum X_i}{\sum X_i^2} + \beta + \frac{\sum X_i E(u_i)}{\sum X_i^2} = \beta + \alpha \frac{\sum X_i}{\sum X_i^2} = \beta + \alpha \frac{n \bar{X}}{\sum X_i^2} \end{aligned} \quad (4-5)$$

توجه شود که در مدل صحیح، $E(u_i) = 0$ است در حالی که در مدلی که عرض از مبدأ آن را حذف کرده ایم، امید ریاضی جمله خطا صفر نمی باشد ($E(v_i) \neq 0$).

بنابراین، $\hat{\beta}^*$ دارای تورش است که علامت تورش عمدتاً بستگی به علامت α و همچنین بستگی به علامت \bar{X} دارد. تورش $\hat{\beta}^*$ وقتی صفر می شود که α یا \bar{X} صفر باشد. یعنی یا واقعاً عرض از

مبدأ صفر باشد و یا متغیر X دارای مقادیر مثبت و منفی باشد به گونه‌ای که میانگین آن صفر گردد.

از طرف دیگر وقتی شرط $\sum e_i = 0$ برقرار باشد، آنگاه $\bar{Y} = \bar{\hat{Y}}$ است، زیرا $Y_i = \hat{Y}_i + e_i$ است و لذا خواهیم داشت:

$$\sum Y_i = \sum \hat{Y}_i + \sum e_i \Rightarrow \bar{Y} = \bar{\hat{Y}} + \bar{e} \Rightarrow \bar{Y} = \bar{\hat{Y}}, \bar{e} = 0 \quad (4-9)$$

برابری $\bar{Y} = \bar{\hat{Y}}$ بدان معنا است که معادله رگرسیون، لااقل مقادیر متوسط \bar{Y} را دقیقاً به ما خواهد داد در حالی که معادله بدون عرض از مبدأ، چنین تضمینی را نمی‌دهد. زیرا $\bar{e} \neq 0$ بوده و لذا $\bar{Y} \neq \bar{\hat{Y}}$ می‌باشد.

نکته دیگر این است که وقتی α را حذف کنیم، ممکن است R^2 منفی شود. طبق تعریف، R^2 برابر است با:

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS}$$

بدین منظور، RSS را در دو حالت بررسی می‌کنیم:

- ۱- اگر معادله شامل عرض از مبدأ باشد، همان‌طور که دیدیم $TSS = \sum \hat{y}_i^2$ و $ESS = \sum \hat{y}_i^2 = \hat{\beta}^2 \sum x_i^2$ است. لذا $ESS \geq 0$ است و در نتیجه $RSS \leq TSS$ بوده که موجب می‌شود تا $R^2 \geq 0$ باشد. از طرف دیگر چون $\sum e_i = 0$ است لذا $\bar{Y} = \bar{\hat{Y}}$ خواهد بود.
- ۲- اگر معادله فاقد عرض از مبدأ باشد، در این صورت $Y_i = \beta X_i + u_i$ و $\hat{Y}_i = \hat{\beta} X_i$ است که در این حالت، شرط $\sum e_i = 0$ برقرار نیست. لذا میانگین Y_i و \hat{Y}_i برابر نیستند.

$$\sum e_i \neq 0 \Rightarrow \sum (Y_i - \hat{Y}_i) \neq 0 \Rightarrow \sum Y_i - \sum \hat{Y}_i \neq 0 \Rightarrow \bar{Y} \neq \bar{\hat{Y}}$$

از طرف دیگر TSS برابر است با:

$$\begin{aligned} TSS &= \sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i + e_i - \bar{Y})^2 = \sum [(\hat{Y}_i - \bar{Y}) + e_i]^2 \\ &= \sum (\hat{Y}_i - \bar{Y})^2 + \sum e_i^2 + 2 \sum e_i (\hat{Y}_i - \bar{Y}) \end{aligned}$$

جمله آخر برابر است با:

$$2 \sum e_i (\hat{Y}_i - \bar{Y}) = 2 \sum e_i \hat{Y}_i - 2 \bar{Y} \sum e_i = 2 \bar{Y} \bar{e}$$

زیرا $\sum e_i \hat{Y}_i = 0$ است. از طرف دیگر در رگرسیون فاقد عرض از مبدأ، $\bar{e} \neq 0$ است که با توجه به $\bar{Y} = \bar{\hat{Y}} + \bar{e}$ خواهیم داشت:

$$\sum \bar{Y} \bar{e} = \sum \bar{Y} (\bar{Y} - \bar{\hat{Y}})$$

بنابراین، TSS برابر است با:

$$TSS = \sum (\hat{Y}_i - \bar{Y})^2 + \sum e_i^2 + \sum \bar{Y} (\bar{Y} - \bar{\hat{Y}})$$

دیدیم که $\sum (\hat{Y}_i - \bar{Y})^2$ معادل با ESS است که در اینجا برابر است با:

$$ESS = TSS - RSS - \sum \bar{Y} (\bar{Y} - \bar{\hat{Y}})$$

در رگرسیون با عرض از مبدأ، $\bar{Y} = \bar{\hat{Y}}$ است و لذا $ESS = TSS - RSS$ می‌باشد، ولی در رگرسیون فاقد عرض از مبدأ، $\bar{Y} \neq \bar{\hat{Y}}$ است و اگر $\bar{Y} > \bar{\hat{Y}}$ باشد، آنگاه ممکن است $ESS = (TSS - RSS) - \sum \bar{Y} (\bar{Y} - \bar{\hat{Y}})$ منفی شود. در این صورت، ESS منفی شده و موجب منفی شدن R^2 خواهد شد.

۳-۴ فرض دوم: واریانس همسانی

اگر جمله خطا دارای واریانس ثابت نباشد، آن را «واریانس ناهمسانی»^۱ می‌گویند که در مقابل «واریانس همسانی»^۲ قرار دارد. در اینجا به بررسی ماهیت واریانس ناهمسانی، پیامدها، آزمون‌های تشخیصی و برطرف کردن آن می‌پردازیم.

۳-۴-۱ ماهیت واریانس ناهمسانی

واریانس ناهمسانی یکی از مشکلاتی است که در برآورد معادلات رگرسیون با آن مواجه می‌شویم. واریانس ناهمسانی بدان معنا است که واریانس e_i (و به دنبال آن واریانس \hat{Y}_i) ثابت نیست و معمولاً همراه با یک یا چند متغیر، افزایش می‌یابد. به ویژه، این پدیده در داده‌های مقطعی بسیار به چشم می‌خورد. به عنوان مثال وقتی مصرف یک کالا را (Y) را روی درآمد (X) برازش

^۱ heteroskedasticity


^۲ homoskedasticity

می‌کنیم و از داده‌های مقطعی (مانند گروه‌های درآمدی) استفاده می‌کنیم؛ در گروه‌های درآمدی پایین، مقدار مصرف کالای مورد نظر به هم نزدیک است ولی در گروه‌های درآمدی بالا، تفاوت‌های بیشتری وجود دارد. این موضوع باعث واریانس ناهمسانی می‌شود که طبق آن، σ_i^2 تابعی از درآمد (X_i) خواهد بود. در داده‌های سری زمانی نیز ممکن است نوسانات یک‌ک متغیر مانند بازده سهام، نرخ ارز و نرخ تورم در طول زمان افزایش یابد که شواهدی از واریانس ناهمسانی هستند.

در رگرسیون $Y_i = \alpha + \beta X_i + u_i$ واریانس u_i و واریانس شرطی Y_i برابر است با:

$$\sigma_i^2 = E(u_i^2 | X_i) = \text{var}(Y_i | X_i) \quad (4-8)$$

نمودار زیر بیانگر واریانس ناهمسانی است:



نمودار ۴-۲: واریانس ناهمسانی

نمودار ۴-۲ نشان می‌دهد که با افزایش X ، پراکندگی Y (واریانس Y) حول میانگین شرطی (خط رگرسیون) در حال افزایش است. بنابراین، واریانس شرطی Y و u تابعی از X است.

$$\sigma_i^2 = E(u_i^2 | X_i) = \text{var}(Y_i | X_i) = f(X_i) \quad (4-9)$$

از طرف دیگر، می‌توان رابطه فوق را برای u_i^2 به صورت زیر نوشت:

$$u_i^2 = E(u_i^2 | X_i) + \varepsilon_i = \sigma_i^2 + \varepsilon_i = f(X_i) + \varepsilon_i \quad ; \quad \varepsilon_i \sim N(0, \sigma_\varepsilon^2) \quad (4-10)$$

از آنجا که مقادیر u_i را نداریم از برآورد آنها، یعنی ε_i ، استفاده می‌کنیم:

(۴-۱۱)

$$e_i^* = f(X_i) + \varepsilon_i$$

معادله فوق یک معادله رگرسیون است که e_i^* را روی X_i برازش می‌کند. تابع f نوع رابطه بین e_i^* و X_i را مشخص می‌کند که می‌تواند هر شکلی داشته باشد. معمولاً هر یک از روش‌های تشخیص واریانس ناهمسانی شکل خاصی از تابع f را در نظر می‌گیرند. البته، نوع دیگری از واریانس ناهمسانی وجود دارد که طبق آن، واریانس u_i تابعی از خطاهای گذشته (u_{i-j}) است. این نوع مدل‌ها معروف به مدل‌های ARCH^۱ می‌باشند که در فصل چهاردهم بحث خواهند شد.

۲-۳-۴ پیامدهای واریانس ناهمسانی

- ۱- واریانس ناهمسانی، ویژگی بدون تورش بودن تخمین‌زننده‌های OLS را تغییر نمی‌دهد.
- ۲- واریانس ناهمسانی، ویژگی سازگاری تخمین‌زننده‌های OLS را تغییر نمی‌دهد.
- ۳- واریانس ناهمسانی، موجب می‌شود که تخمین‌زننده‌های OLS، کارا نباشند، یعنی حداقل واریانس را ندارند. به‌طور کلی برآورد واریانس جمله خطا دچار تورش می‌شود.
- ۴- از آنجا که واریانس‌ها به‌درستی برآورد نمی‌شوند، لذا آزمون فرضیه‌هایی که با F ، t و χ^2 انجام می‌شوند، قابل اطمینان نخواهند بود.

۳-۳-۴ برآورد واریانس مستحکم^۲ وایت

یکی از پیامدهای واریانس ناهمسانی آن است که برآورد $\hat{\sigma}^2$ دارای تورش است و لذا تمامی آزمون‌های فرضیه را مخدوش می‌کند. برای حل این مشکل و برآورد بهتری از واریانس، روشی توسط وایت معرفی شده است که در اینجا آن را تشریح می‌کنیم.

در فصل دوم برای معادله رگرسیون ساده $Y_i = \alpha + \beta X_i + u_i$ ، تخمین β از روش OLS را به‌صورت زیر به‌دست آوردیم:

$$\hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2} = \sum w_i Y_i = \beta + \sum w_i u_i \quad ; \quad w_i = \frac{x_i}{\sum x_i^2}$$

^۱ Autoregressive Conditional Heteroskedasticity

^۲ robust

دیدیم که واریانس $\hat{\beta}$ در صورت واریانس همسانی، برابر است با:

$$\text{var}(\hat{\beta}) = E(\hat{\beta} - \beta)' = \sum w_i' E(u_i') = \frac{\sum x_i' E(u_i')}{(\sum x_i')'} = \frac{(\sum x_i') \sigma^2}{(\sum x_i')'} = \frac{\sigma^2}{\sum x_i'}$$

حال در صورت واریانس ناهمسانی، واریانس $\hat{\beta}$ برابر است با:

$$\text{var}(\hat{\beta}) = \frac{\sum x_i' E(u_i')}{(\sum x_i')'} = \frac{\sum x_i' \sigma_i^2}{(\sum x_i')'} \quad (4-12)$$

بنابراین در صورت واریانس همسانی، واریانس $\hat{\beta}$ برابر با $\sigma^2 / \sum x_i'$ است که $\hat{\sigma}^2 = \frac{\sum e_i^2}{n-2}$ می‌باشد. لذا واریانس $\hat{\beta}$ به صورت زیر محاسبه می‌شود:

$$\text{var}(\hat{\beta}) = \frac{\hat{\sigma}^2}{\sum x_i'} = \frac{\sum \frac{1}{n-2} e_i^2}{\sum x_i'} \quad (4-13)$$

معادله فوق نشان می‌دهد که در محاسبه واریانس $\hat{\beta}$ وزن e_i^2 ها یکسان بوده و برابر با $\frac{1}{n-2}$ می‌باشد.

وایت (۱۹۸۰) پیشنهاد می‌کند که برای برآورد سازگار $\text{var}(\hat{\beta})$ از (4-12) به صورت زیر

استفاده کنیم که مشابه (4-13) است ولی به جای $\frac{1}{n-2}$ از $\frac{x_i^2}{\sum x_i'}$ استفاده می‌شود:

$$\text{var}(\hat{\beta})_{\text{White}} = \frac{\sum x_i' e_i^2}{(\sum x_i')'} = \frac{\sum \frac{x_i^2 e_i^2}{\sum x_i'}}{\sum x_i'} = \frac{\sum k_i e_i^2}{\sum x_i'} \quad ; \quad k_i = \frac{x_i^2}{\sum x_i'} \quad (4-14)$$

توجه شود که در اینجا تخمین σ_i^2 را نمی‌توانیم به دست آوریم، زیرا e_i^2 فقط یک مشاهده است. لذا فقط تخمین سازگار واریانس $\hat{\beta}$ را به دست آورده‌ایم، یعنی تخمین سازگار برای واریانس تخمین‌زنده‌های OLS. بنابراین روش وایت از باقیمانده‌های OLS استفاده می‌کند و واریانس $\hat{\beta}$ را اصلاح می‌کند به گونه‌ای که سازگار شود. لذا می‌توان آن را برای آزمون‌های فرضیه مورد استفاده قرار داد.

حال اگر رگرسیون K متغیره باشد، واریانس $\hat{\beta}_k$ که ضریب X_{kt} است به صورت زیر پیشنهاد می شود:

$$\text{var}(\hat{\beta}_k)_{White} = \frac{\sum_{t=1}^n \hat{\varepsilon}_{kt}^2 e_t^2}{\left(\sum_{t=1}^n \hat{\varepsilon}_{kt}^2 \right)^2} \quad (۴-۱۵)$$

که ε_{kt} جملات خطای معادله رگرسیون $X_{kt} = \alpha_0 + \alpha_1 e_t + \varepsilon_{kt}$ است.

فایل data5

برآورد واریانس وایت در Eviews

به منظور برآورد واریانس وایت، با استفاده از مسیر Quick → Estimate Equation پنجره زیر را باز می کنیم:

Equation Estimation

Specification Options

Equation specification

Dependent variable followed by list of regressors including ARMA and PDL terms, OR an explicit equation like Y=C(1)+C(2)*X.

Y C X2 X3

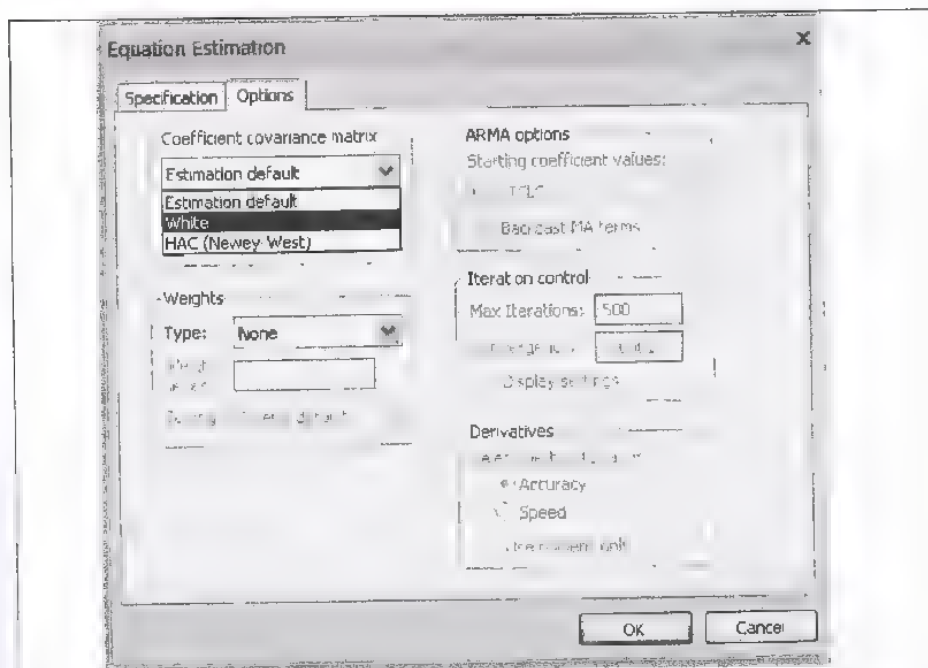
Estimation settings

Method: LS - Least Squares (NLS and ARMA)

Sample: 1952Q1 1996Q4

OK Cancel

معادله موردنظر را در قسمت Equation Specification وارد می کنیم (به صورت Y C X2 X3). سپس با انتخاب گزینه options پنجره زیر را باز می کنیم:



در سمت Coefficient Covariance matrix گزینه white را انتخاب می‌کنیم و معادله را تخمین می‌زنیم. این در حالی است که با انتخاب گزینه Estimation default واریانس‌های معمولی را حساب می‌کند. توجه شود که هرچند σ^2 هیچ تفاوتی نمی‌کند، ولی با انتخاب گزینه white، واریانس و انحراف معیار ضرایب متفاوت خواهد بود.

Equation: UNTITLED Workfile: DATA5:Untitled					
View	Proc	Object	Print	Name	Freeze
Estimate	Forecast	Stats	Resids		
Dependent Variable: Y2					
Method: Least Squares					
Date: 12/26/13 Time: 13:49					
Sample (adjusted): 1355 1386					
Included observations: 32 after adjustments					
White heteroskedasticity-consistent standard errors & covariance					
Variable	Coefficient	Std. Error	t-Statistic	Prob	
C	8.348042	0.084660	98.60705	0.0000	
X1	0.032141	0.007731	4.157231	0.0003	
X2	0.027725	0.000237	117.2260	0.0000	
R-squared	0.997950	Mean dependent var	9.614329		
Adjusted R-squared	0.997808	S.D. dependent var	0.266791		
S.E. of regression	0.012490	Akaike info criterion	-5.838782		
Sum squared resid	0.004524	Schwarz criterion	-5.701349		
Log likelihood	96.42019	Hannan-Quinn criter.	-5.793214		
F-statistic	7057.919	Durbin-Watson stat	0.519669		
Prob(F-statistic)	0.000000				

۴-۳-۴ آزمون‌های تشخیص واریانس ناهمسانی

آزمون‌های آماری مختلفی برای تشخیص واریانس ناهمسانی وجود دارد که در اینجا به برخی از این آزمون‌ها و نحوه انجام آنها با Eviews می‌پردازیم.

الف) آزمون بارتلت

آزمون بارتلت (۱۹۷۳) وقتی قابل کاربرد است که مشاهدات تکراری باشند. به عنوان مثال برای برآورد رابطه بین مصرف یک کالا با درآمد خانوار، مشاهدات تکراری وجود دارد. زیرا براساس آمار هزینه و درآمد خانوارها، مقادیر مصرف و درآمد هم بر حسب گروه‌های درآمدی و هم بر حسب سال موجود است. لذا اگر مصرف کالای Y را تابعی از درآمد (X) بدانیم، آنگاه در سال اول n_1 خانوار (یا گروه درآمدی) داریم که برای آنها می‌توان معادله $Y_i = \alpha + \beta X_i + u_i$ را برآورد نمود. حال اگر t سال را در نظر بگیریم آنگاه معادله $Y_{it} = \alpha + \beta X_{it} + u_{it}$ را داریم که باقیمانده‌های آن e_{it} می‌باشند. حال برای خانوار نام (یا گروه درآمدی) نام T مشاهده داریم. بنابراین اگر معتقد باشیم که در این مدل، مشکل واریانس ناهمسانی وجود دارد و مسئله واریانس ناهمسانی بدین صورت است که با افزایش درآمد (X) واریانس‌ها افزایش می‌یابند، می‌توان برای هر خانوار یا گروه درآمدی، واریانس را به‌طور جداگانه حساب نمود. بدین منظور e_{it} ‌ها را برای هر خانوار یا گروه درآمدی به صورت زیر نوشته و واریانس مربوطه را حساب می‌کنیم:

$$\begin{aligned} \sum_{i=1}^T e_{1i}^2 &\Rightarrow \hat{\sigma}_1^2 = \frac{T-1}{T-1} \quad \text{گروه درآمدی ۱} \\ \sum_{i=1}^T e_{2i}^2 &\Rightarrow \hat{\sigma}_2^2 = \frac{T-1}{T-1} \quad \text{گروه درآمدی ۲} \\ &\vdots \\ \sum_{i=1}^T e_{ni}^2 &\Rightarrow \hat{\sigma}_n^2 = \frac{T-1}{T-1} \quad \text{گروه درآمدی } n \end{aligned} \quad (۴-۱۶)$$

اگر واریانس‌ها برابر باشند، آنگاه بایستی که $\hat{\sigma}_i^2$ ‌ها به هم نزدیک باشند، در غیر این صورت دارای تفاوت‌های اساسی بوده که بیانگر واریانس ناهمسانی است. بارتلت آماره‌ای را برای آزمون

فرضیه $H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2$ ارائه می‌کند که شکل کلی آن برای حالتی که n گروه داشته و برای هر گروه T_i مشاهد داشته باشیم به صورت زیر است:

$$B = \frac{1}{f} \left[(N-n) \log \hat{\sigma}^2 - \sum_{i=1}^n (T_i-1) \log \hat{\sigma}_i^2 \right] \quad (4-17)$$

$$f = 1 + \frac{1}{2(n-1)} \left[\sum_{i=1}^n \frac{1}{T_i-1} - \frac{1}{N-1} \right] ; \quad N = \sum_{i=1}^n T_i$$

$\hat{\sigma}^2$ میانگین واریانس‌ها است که برابر است با:

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (T_i-1) \hat{\sigma}_i^2}{\sum_{i=1}^n (T_i-1)} = \frac{\sum_{i=1}^n (T_i-1) \hat{\sigma}_i^2}{N-n} \quad (4-18)$$

اگر T_i ها یکسان باشند، $\hat{\sigma}^2$ عبارت است از:

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (T_i-1) \hat{\sigma}_i^2}{\sum_{i=1}^n (T_i-1)} = \frac{(T-1) \sum_{i=1}^n \hat{\sigma}_i^2}{nT-n} = \frac{\sum_{i=1}^n \hat{\sigma}_i^2}{n-1} \quad (4-19)$$

بدیهی است که اگر T_i ها یکسان باشند، آنگاه آماره B به صورت زیر نوشته می‌شود (توجه

شود که در این حالت $N = \sum T_i = nT$ است):

$$B = \frac{T-1}{f} \left(n \log \hat{\sigma}^2 - \sum_{i=1}^n \log \hat{\sigma}_i^2 \right) \quad (4-20)$$

$$f = 1 + \frac{1}{2(n-1)} \left[\frac{n}{T-1} - \frac{1}{nT-1} \right] = 1 + \frac{n+1}{2(T-1)}$$

B را می‌توان به صورت $\frac{T-1}{f} \log \frac{(\hat{\sigma}^2)^n}{\hat{\sigma}_1^2 \hat{\sigma}_2^2 \dots \hat{\sigma}_n^2}$ نوشت. بدیهی است که اگر همه واریانس‌ها برابر

باشند آنگاه مخارج کسر نیز برابر با $(\hat{\sigma}^2)^n$ می‌شود که در این صورت، آماره B برابر صفر خواهد

شد. در غیر این صورت، آماره B بزرگ شده و در ناحیه بحرانی قرار می‌گیرد که بیانگر رد H_0

(رد واریانس همسانی) می‌شود. آماره B توزیع χ^2 با درجه آزادی $n-1$ دارد.

ب) آزمون گلدفلد-کوآنت^۱

در این آزمون فرض بر این است که مشاهدات را می‌توان به دو گروه تقسیم نمود و سپس آزمون یکسان بودن واریانس بین این دو گروه را انجام داد. مراحل این آزمون را به صورت زیر است:

- ۱- فرض کنید در رگرسیون $Y_i = \alpha + \beta X_i + u_i$ رابطه $\sigma_1^2 = \sigma^2 X_i^2$ برقرار است. این بدان معنا است که عامل واریانس ناهمسانی، متغیر X_i است.
- ۲- مشاهدات را براساس مقادیر X_i از کوچک به بزرگ مرتب کرده و سپس آنها را به سه گروه تقسیم می‌کنیم:

- گروه ابتدایی با حجم n_1 که آن را گروه ۱ می‌نامیم.

- گروه میانی با حجم m .

- گروه آخر با حجم n_2 که آن را گروه ۲ می‌نامیم.

بدیهی است که $n_1 + m + n_2 = n$ می‌باشد.

- ۳- معادله رگرسیون را برای گروه اول و دوم برآورد کرده و RSS ها را حساب می‌کنیم. مجموع مجذور خطاها را برای گروه اول و دوم به ترتیب با RSS_1 و RSS_2 نشان می‌دهیم.

- ۴- فرضیه $H_0: \sigma_1^2 = \sigma_2^2 = \sigma^2$ را آزمون می‌کنیم. این فرضیه بدان معنا است که واریانس گروه ۱ و ۲ یکسان هستند. برای انجام این آزمون ابتدا $\hat{\sigma}_1^2$ و $\hat{\sigma}_2^2$ را حساب می‌کنیم که تحت فرضیه H_0 ، هر یک از آنها تخمین زننده σ^2 هستند. برای هر یک از این واریانس‌ها، روابط زیر برقرار است^۲:

$$\frac{\hat{\sigma}_1^2}{\sigma^2} = \frac{\chi_{n_1-K}^2}{n_1-K}, \quad \frac{\hat{\sigma}_2^2}{\sigma^2} = \frac{\chi_{n_2-K}^2}{n_2-K} \quad (4-21)$$

حال آماره F را برای مقایسه واریانس‌ها، تحت فرضیه H_0 تشکیل می‌دهیم:

$$F_{n_1-K, n_2-K} = \frac{\chi_{n_1-K}^2 / n_1 - K}{\chi_{n_2-K}^2 / n_2 - K} = \frac{\hat{\sigma}_1^2}{\hat{\sigma}_2^2} = \frac{RSS_1 / n_1 - K}{RSS_2 / n_2 - K} = \frac{n_2 - K}{n_1 - K} \frac{RSS_1}{RSS_2} \quad (4-22)$$

^۱Goldfeld-Quandt Test

^۲فصل اول بخش ۲-۷-۱ و ۴-۷-۱ را ببینید.

اگر مقدار F بزرگ باشد، در ناحیه بحرانی قرار می‌گیرد و فرضیه H_0 را رد می‌کند.

ج) آزمون گلجر^۱

آزمون گلجر قدر مطلق خطاها را روی متغیری که انتظار می‌رود واریانس ناهمسانی را توضیح می‌دهد (مانند Z) برازش می‌کند. شکل کلی چنین تابعی به صورت $|e_i| = \alpha_0 + \alpha_1 Z_i^\gamma + v_i$ است. از آنجا که این یک تابع غیرخطی است، لذا به ازای مقادیر مختلف γ برآورد می‌شود. معمولاً مقایری که برای γ در نظر گرفته می‌شود شامل -1 ، -0.5 ، 0.5 و 1 می‌باشد. به هر حال، معنادار بودن α_1 بیانگر رد فرضیه واریانس همسانی است.

د) آزمون همبستگی رتبه‌ای اسپیرمن^۲

اگر هدف ما بررسی رابطه بین واریانس u_i و X_i باشد می‌توان از ضریب همبستگی رتبه‌ای استفاده نمود. بدین منظور قدر مطلق e_i ها را حساب کرده و سپس آنها و همچنین X_i ها را رتبه‌بندی می‌کنیم. آنگاه تفاوت رتبه‌ها را حساب می‌کنیم:

$$X_i \text{ و } |e_i| \text{ تفاوت رتبه } = d_i = R_{|e_i|} - R_{X_i} \quad (4-23)$$

R_{X_i} و $R_{|e_i|}$ به ترتیب رتبه‌های X_i و $|e_i|$ را نشان می‌دهند. ضریب همبستگی اسپیرمن را به صورت زیر محاسبه می‌شود:

$$r_s = 1 - \frac{\sum_{i=1}^n d_i^2}{n(n-1)} \quad (4-24)$$

حال فرضیه عدم همبستگی بین X_i و e_i ، یعنی فرضیه $H_0: r_s = 0$ را آزمون می‌کنیم. فرضیه H_0 بیانگر واریانس همسانی است. معنی‌دار بودن ضریب همبستگی را می‌توان با آماره t آزمون نمود^۱:

^۱Golejser test

^۲Spearman's rank correlation test

$$t_{n-2} = \frac{r_s}{\sqrt{\frac{1-r_s^2}{n-2}}} \quad (4-25)$$

اگر فرضیه H_0 درست باشد، آنگاه $r_s = 0$ بوده و آماره t صفر می‌شود. در غیر این صورت آماره t بزرگ بوده و در ناحیه بحرانی قرار می‌گیرد که فرضیه H_0 را رد می‌کند. رد H_0 بیانگر آن است که واریانس ناهمسانی وجود دارد.

۱-۱-۱. آزمون بروش-پاگان-کادفری^۲

آزمون بروش-پاگان برداری از متغیرها را که ممکن است موجب واریانس ناهمسانی شده باشند، در نظر می‌گیرد. شکل کلی این تابع به صورت زیر است:

$$\sigma_i^2 = E(u_i^2) = h(\alpha_0 + \alpha_1 Z_{i1} + \dots + \alpha_r Z_{ir}) \quad (4-26)$$

Z_{ik} ها می‌توانند دقیقاً با متغیرهای توضیحی (یعنی X_{ik} ها) یکسان باشند یا متفاوت باشند. واریانس ناهمسانی توسط فرضیه $H_0: \alpha_1 = \dots = \alpha_r = 0$ توصیف می‌شود. آزمون بروش-پاگان را می‌توان به صورت مراحل زیر انجام داد:

۱- ابتدا معادله $Y_i = \beta_1 + \beta_2 X_{i1} + \dots + \beta_K X_{iK} + u_i$ را با روش OLS برآورد کرده و باقیمانده‌ها (e_i) را حساب می‌کنیم.

۲- واریانس معادله رگرسیون را به صورت $\hat{\sigma}^2 = \frac{\sum e_i^2}{n}$ حساب می‌کنیم.

۳- رگرسیون $\frac{e_i^2}{\hat{\sigma}^2} = \alpha_0 + \alpha_1 Z_{i1} + \alpha_2 Z_{i2} + \dots + \alpha_r Z_{ir} + \varepsilon_i$ را با روش OLS برآورد کرده و مجموع تغییرات توضیح داده شده (ESS_a) را حساب می‌کنیم.

۴- تحت فرضیه H_0 رابطه زیر برقرار است:

$$\frac{1}{r} ESS_a \sim \chi_{r-1}^2 \quad (4-27)$$

^۱ فصل دوم بخش ۱۰-۲ را ببینید.

^۲ Breusch-Pagan test

بنابراین، اگر $\frac{ESS_a}{p}$ بزرگتر از $\chi^2_{1-\alpha, p-1}$ باشد، فرضیه H_0 (واریانس همسانی) رد می‌شود. زیرا در این حالت، متغیرهای Z_{it} توانسته‌اند $\sigma^2_{\epsilon_i}$ یا e_i^2 را توضیح دهند.

۵- از طرف دیگر می‌توان نشان داد که اگر R_a^2 (به‌دست آمده از بند ۳) را در تعداد مشاهدات ضرب کنیم، آنگاه nR_a^2 توزیع χ^2_{p-1} دارد^۱ که مشابه نتیجه حاصل از بند ۴ است.

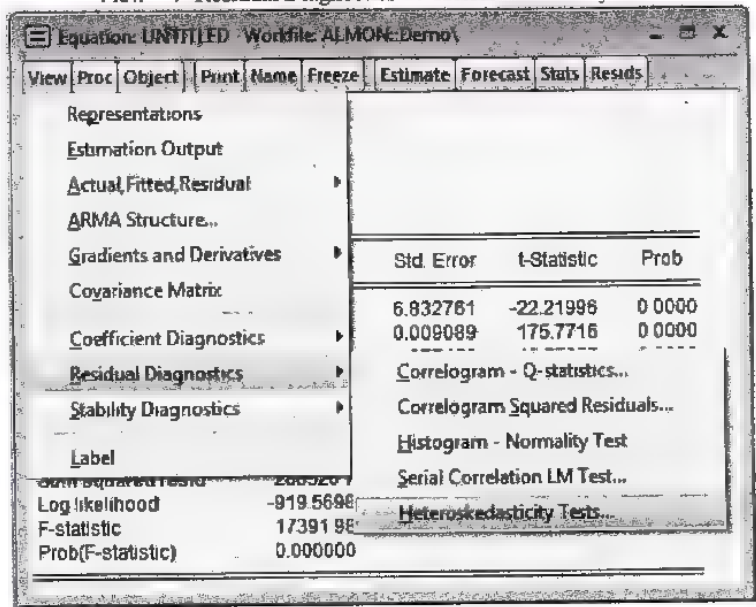
و) آزمون هاروی^۲

آزمون هاروی نیز مشابه آزمون‌های گلدجر و بروش-پاگان-گادفری است. در آزمون هاروی به‌جای $|e_i|$ و e_i^2 از لگاریتم مجذور خطاها ($\log e_i^2$) استفاده می‌شود. در این روش $\log e_i^2$ روی متغیرهای توضیحی و یا هر متغیری که موجب واریانس ناهمسانی شده است، برازش می‌شود.

آزمون‌های واریانس ناهمسانی در Eviews

برای انجام آزمون واریانس ناهمسانی، در پنجره نتایج مسیر زیر را انتخاب می‌کنیم:

View → Residual Diagnostics → Heteroskedasticity Test



	Std. Error	t-Statistic	Prob
6.832761	-22.21996	0.0000	
0.009089	175.7716	0.0000	

Other Squared Resid 200320

Log likelihood -919.5698

F-statistic 17391.98

Prob(F-statistic) 0.000000

Correlogram - Q- statistics...

Correlogram Squared Residuals...

Histogram - Normality Test

Serial Correlation LM Test...

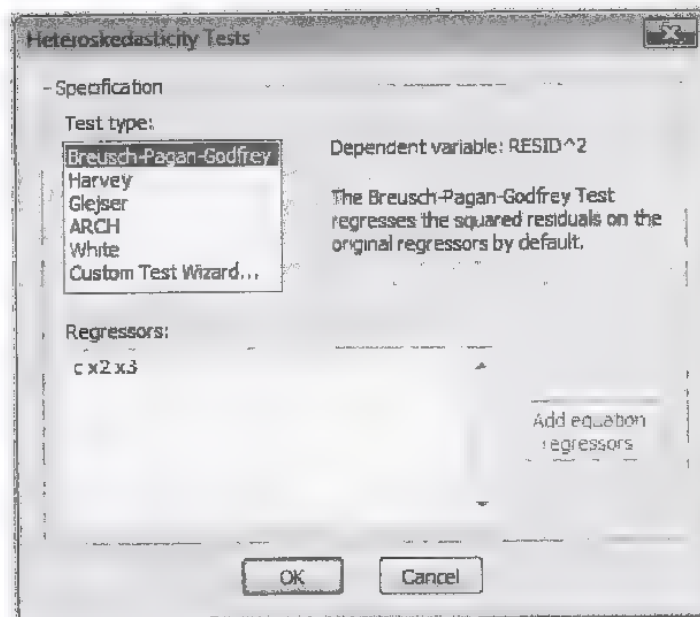
Heteroskedasticity Tests...

سپس در پنجره زیر نوع آزمون واریانس ناهمسانی را انتخاب می‌کنیم. آزمون‌های گادفری-بریش-پاگان، هاروی و گلدجر مشابه

^۱ فصل هفتم بخش ۱۵-۷ را ببینید.

^۲ Harvey

هم هستند و فقط متغیر وابسته آنها متفاوت است که به ترتیب به صورت e_t^2 ، $\log(e_t^2)$ و $|e_t^2|$ می‌باشند. در همه این آزمون‌ها دو قیمت Regressors هر متغیری که تصور می‌رود موجب واریانس ناهمسانی می‌شود وارد می‌کنیم. اگر گزینه Arch را انتخاب کنیم نوع خاصی از واریانس ناهمسانی را آزمون می‌کند که جزئیات آن در فصل سیزدهم بحث شده است. گزینه White نیز آزمون وایت را انجام می‌دهد که در بخش بعدی بررسی شده است.



ز) آزمون وایت^۱

آزمون وایت حالت عمومی‌تری از آزمون بروش-پاگان-گادفری است. در آزمون وایت، فرضیه واریانس همسانی به صورت $H_0: \sigma_t^2 = \sigma^2$ معرفی می‌شود. مراحل انجام این آزمون به صورت زیر است:

۱- معادله رگرسیون زیر را در نظر بگیرید:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + u_t \quad (4-28)$$

برای آزمون «واریانس همسانی»، معادله (۴-۲۸) را برآورد کرده و باقیمانده‌ها (e_t) را حساب می‌کنیم.

^۱White

۲- معادله رگرسیون زیر را برآورد می‌کنیم:

$$e_i^* = \alpha_1 + \alpha_2 X_{it} + \alpha_3 X_{it}^2 + \alpha_4 X_{it}^3 + \alpha_5 X_{it}^4 + \alpha_6 X_{it} X_{it}^2 + \alpha_7 X_{it} X_{it}^3 + v_i \quad (4-29)$$

v_i جمله خطا است. در این رگرسیون از مجذور خطاها استفاده شده است، زیرا:

$$\text{var}(e_i) = E(e_i - E(e_i))^2 = E(e_i^2) \quad ; \quad E(e_i) = 0 \quad (4-30)$$

بنابراین، معادله (۴-۲۹) در واقع معادله میانگین شرطی برای e_i^* است که بر اساس آن، رابطه زیر را می‌توان نوشت که همان معادله (۴-۲۹) می‌باشد:

$$e_i^* = E(e_i^*) + v_i = \alpha_1 + \alpha_2 X_{it} + \alpha_3 X_{it}^2 + \alpha_4 X_{it}^3 + \alpha_5 X_{it}^4 + \alpha_6 X_{it} X_{it}^2 + \alpha_7 X_{it} X_{it}^3 + v_i \quad (4-31)$$

۳- با توجه به معادله رگرسیون e_i^* ، می‌توان آزمون‌های مختلفی را انجام داد. به عنوان نمونه، می‌توان از آزمون F که در فصل سوم بحث شد استفاده نمود. این روش مستلزم تخمین معادله (۴-۲۹) و همچنین تخمین معادله زیر است:

$$e_i^* = \alpha_1 + v_i \quad (4-32)$$

در واقع معادله (۴-۲۹) تخمین نامقید و معادله (۴-۳۲) بیانگر تخمین مقید است که در آن ضرایب $\alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = \alpha_5 = \alpha_6 = \alpha_7 = 0$ می‌باشد. حال RSS را برای هر یک از این دو معادله حساب کرده و F را برای آزمون آن، تشکیل می‌دهیم:

$$F = \frac{n-K}{m} \frac{RSS_R - RSS_{UR}}{RSS_{UR}} \quad (4-33)$$

RSS_{UR} و RSS_R به ترتیب RSS مقید (معادله ۴-۳۲) و نامقید (معادله ۴-۲۹) می‌باشند. K تعداد ضرایب و m تعداد محدودیت‌ها است که در اینجا $K=6$ و $m=5$ می‌باشد. اگر اختلاف این دو رگرسیون زیاد باشد در این صورت مقدار F بزرگتر شده و بدین معنی است که فرضیه H_0 (یعنی ثابت بودن واریانس) رد می‌شود. بدیهی است که اگر $\alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = \alpha_5 = \alpha_6 = \alpha_7 = 0$ باشد، بدین معنی است که واریانس ثابت است.

روش دیگر برای آزمون واریانس همسانی معروف به آزمون ضریب لاگرانژ (LAM)^۱ است که نیازی به برآورد معادله (۴-۳۲) یعنی معادله رگرسیون مقید ندارد. در این روش از مقدار R^2 در

۱- Lagrange Multiplier. جزئیات این روش در فصل هفتم بخش ۷-۱۵ بحث شده است.

معادله (۴-۲۹) استفاده می‌شود. اگر یک یا چند ضریب در معادله (۴-۲۹) از نظر آماری معنی‌دار باشند، مقدار R^2 نسبتاً بزرگ خواهد بود. و در غیر این صورت مقدار R^2 کوچک خواهد بود. لذا آزمون LM بر اساس حاصل ضرب R^2 در تعداد مشاهدات است که دارای توزیع χ_m^2 می‌باشد:

$$nR^2 \sim \chi_m^2 \quad (۴-۳۴)$$

m تعداد ضرایب تخمینی در معادله (۴-۲۹) (به استثنای جمله ثابت) است و از طرف دیگر برابر با تعداد محدودیت‌ها در آزمون F می‌باشد.

در آزمون LM ، فرضیه مورد نظر به صورت زیر بیان می‌شود:

$$H_0: \alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = \alpha_5 = 0 \quad (۴-۳۵)$$

در آزمون LM اگر مقدار $nR^2 = \chi_m^2$ بزرگتر از مقدار بحرانی باشد، سپس فرضیه H_0 رد می‌شود و بدین معنی است که واریانس جمله خطا، ثابت نمی‌باشد.

فایل data2

آزمون وایت در Eviews

برای انجام آزمون وایت، ابتدا معادله رگرسیون را بر آورده می‌کنیم. در اینجا از رگرسیون نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) استفاده می‌کنیم که روی رشد نیروی کار (GL) و رشد سرمایه (GK) و سهم مخارج مصرفی دولت از تولید ناخالص داخلی (SG) پرازش شده است.

Equation: UNTITLED Workfile: GOVERNMENT AND G...				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: GYNO				
Method: Least Squares				
Date: 01/23/11 Time: 18:54				
Sample (adjusted): 1346 1379				
Included observations: 34 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob
GL	1.060829	0.182337	5.817965	0.0000
GK	0.386531	0.087822	4.401316	0.0001
SG	0.039558	0.055057	0.718497	0.4778
R-squared	0.703292	Mean dependent var	5.845234	
Adjusted R-squared	0.684149	S.D. dependent var	7.602924	
S.E. of regression	4.272889	Akaike info criterion	5.826555	
Sum squared resid	565.9849	Schwarz criterion	5.961233	
Log likelihood	-96.05143	Hannan-Quinn criter.	5.872484	
Durbin-Watson stat	1.591813			

در پنجره فوق، از منوی View مسیر زیر دنبال می‌کنیم:

View → Residual Tests → White Heteroskedasticity (no cross term)

توجه شود که no cross term بدین معنی است که حاصل ضرب مقاطع بین متغیرهای توضیحی را در نظر نمی‌گیرد (جملاتی مانند $X_{it}X_{jt}$)، در حالی که اگر گزینه فوق را همراه با cross term انتخاب کنیم، حاصل ضرب‌های مقاطع را نیز در نظر می‌گیرد. نتایج آزمون وایت به صورت جدول زیر نشان داده می‌شود:

Equation: UNTITLED Workfile: GOVERNMENT AND GR...				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Heteroskedasticity Test: White				
F-statistic	1.695178	Prob. F(9,24)	0.1452	
Obs*R-squared	13.21369	Prob. Chi-Square(9)	0.1532	
Scaled explained SS	11.62044	Prob. Chi-Square(9)	0.2356	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 01/23/11 Time: 19:41				
Sample: 1348 1379				
Included observations: 34				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-155.1392	113.2886	-1.369415	0.1835
GL	11.33672	6.814221	1.663685	0.1092
GL^2	-0.432020	0.247380	-1.746387	0.0935
GL*GK	0.110189	0.119207	0.924348	0.3645
GL*SG	-0.431259	0.333643	-1.292578	0.2085
GK	-1.736099	4.263417	-0.407208	0.6875
GK^2	0.109187	0.064568	1.691051	0.1038
GK*SG	0.052044	0.242705	0.214432	0.8320
SG	16.12752	12.74878	1.265025	0.2180
SG^2	-0.378120	0.353650	-1.069184	0.2956
R-squared	0.388638	Mean dependent var	16.52234	
Adjusted R-squared	0.159377	S.D. dependent var	25.20729	
S.E. of regression	23.11143	Akaike info criterion	9.359460	
Sum squared resid	12819.32	Schwarz criterion	9.807390	
Log likelihood	-149.0938	Hannan-Quinn criter.	9.511558	
F-statistic	1.695178	Durbin-Watson stat	2.462716	
Prob(F-statistic)	0.145172			

مقدار F و همچنین nR^2 و احتمال‌های مربوطه نشان می‌دهد که این مدل، واریانس ناهمسانی ندارد. در واقع بر اساس F هر سطح ۵ درصد، وجود واریانس ناهمسانی رد می‌شود. توجه شود که مقدار احتمال برای F برابر با ۱۴/۵۲ درصد به دست آمده است. هر اینجا چون nR^2 نیز محاسبه شده است در قسمت بالای جدول با Obs*R-squared نشان داده شده است. لذا آزمون LM و وایت همراه با هم صورت گرفته است.

۴-۳-۵ تخمین ضرایب با وجود واریانس ناهمسانی

روش حداقل مربعات وزنی (WLS) یا روش حداقل مربعات تعمیم یافته (GLS)

برای توصیف روش GLS یا WLS، ابتدا حالت ساده‌ای را در نظر بگیرید که مدل K متغیره دارای واریانس ناهمسانی است. فرض کنید که واریانس u_i برابر با σ_i^2 است که ناشی از X_{ji} می‌باشد.

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_j X_{ji} + \dots + \beta_K X_{Ki} + u_i \quad (4-36)$$

$$\text{var}(u_i) = E(u_i^2) = \sigma_i^2 = \sigma^2 X_{ji}^2$$

برای حل مشکل واریانس ناهمسانی، طرفین معادله رگرسیون را بر X_{ji} تقسیم می‌کنیم (اگر طرفین را بر σ_i که برابر با σX_{ji} است تقسیم کنیم، همین نتیجه به دست می‌آید):

$$\frac{Y_i}{X_{ji}} = \beta_1 \frac{1}{X_{ji}} + \beta_2 \frac{X_{2i}}{X_{ji}} + \dots + \beta_j + \dots + \beta_K \frac{X_{Ki}}{X_{ji}} + \frac{u_i}{X_{ji}}$$

متغیرهای فوق را که بر X_{ji} تقسیم شده‌اند با علامت ستاره و همچنین $\frac{1}{X_{ji}}$ را با X_{ji}^* نشان

می‌دهیم:

$$Y_i^* = \beta_1 + \beta_2 X_{2i}^* + \dots + \beta_j X_{ji}^* + \dots + \beta_K X_{Ki}^* + u_i^* \quad (4-37)$$

می‌توان نشان داد که مدل فوق دارای واریانس همسانی است:

$$\text{var}(u_i^*) = E(u_i^{*2}) = E\left(\frac{u_i^2}{X_{ji}^2}\right) = \frac{E(u_i^2)}{X_{ji}^2} = \frac{\sigma_i^2}{X_{ji}^2} = \frac{\sigma^2 X_{ji}^2}{X_{ji}^2} = \sigma^2$$

بنابراین می‌توان مدل فوق را با روش OLS تخمین زد، زیرا واریانس ناهمسانی ندارد. در حالت کلی، شکل ماتریس معادله K متغیره به صورت زیر است.

$$y = X\beta + u \quad (4-38)$$

ماتریس واریانس u عبارت است از:

$$\Omega = \text{var}(u) = E(uu') = E \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} [u_1 \quad u_2 \quad \dots \quad u_n]$$

$$= E \begin{bmatrix} u_1^2 & u_1 u_2 & \dots & u_1 u_n \\ u_2 u_1 & u_2^2 & \dots & u_2 u_n \\ \vdots & \vdots & \ddots & \vdots \\ u_n u_1 & u_n u_2 & \dots & u_n^2 \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1n} & \sigma_{2n} & \dots & \sigma_n^2 \end{bmatrix} \quad (4-39)$$

اگر u_i ها خود همبستگی نداشته باشند آنگاه $\sigma_{ij} = 0$ خواهد بود و لذا Ω یک ماتریس قطری خواهد بود.

$$\Omega = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_n^2 \end{bmatrix} \quad (4-40)$$

اگر واریانس همسانی برقرار باشد، آنگاه Ω برابر است با:

$$\Omega = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \mathbf{I}_n \quad (4-41)$$

از طرف دیگر، تخمین زننده OLS برای β و σ^2 به صورت زیر است^۱:

$$\hat{\beta}_{OLS} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \quad (4-42)$$

$$\hat{\sigma}^2 = \frac{e'e}{n-K} = \frac{\sum e_i^2}{n-K}, \quad \hat{\Omega} = \hat{\sigma}^2 \mathbf{I}_n \quad (4-43)$$

اگر از (۴-۳۸) به جای y در (۴-۴۲) جایگذاری کنیم به $\hat{\beta}_{OLS} = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u}$ می‌رسیم.

حال واریانس $\hat{\beta}_{OLS}$ برابر است با:

$$\begin{aligned} \text{var}(\hat{\beta}) &= E(\hat{\beta} - \beta)(\hat{\beta} - \beta)' = E[(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u}\mathbf{u}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}] \\ &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' E(\mathbf{u}\mathbf{u}') \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \\ &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \Omega \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \end{aligned} \quad (4-44)$$

بنابراین اگر شرط واریانس همسانی برقرار باشد، در این صورت $\Omega = \sigma^2 \mathbf{I}_n$ است و لذا توزیع

تخمین زننده $\hat{\beta}_{OLS}$ عبارت است از:

^۱ فصل سوم بخش ۳-۱۰ را ببینید.

$$\hat{\beta}_{OLS} \sim N(\beta, \sigma^2 (X'X)^{-1}) \quad (4-45)$$

اما اگر واریانس همسانی برقرار نباشد، در این صورت توزیع $\hat{\beta}$ با روش OLS عبارت است از:

$$\hat{\beta}_{OLS} \sim N(\beta, (X'X)^{-1} (X'\Omega X) (X'X)^{-1}) \quad (4-46)$$

مقایسه نتایج (۴-۴۵) و (۴-۴۶) نشان می‌دهد که اگر مدل رگرسیون دارای واریانس ناهمسانی باشد و آن را نادیده بگیریم، در این صورت تخمین واریانس‌ها به درستی انجام نخواهد شد. برای حل این مشکل، ابتدا بایستی مدل را به گونه‌ای تبدیل کنیم که واریانس ناهمسانی آن برطرف شود و سپس $\hat{\beta}$ را تخمین بزنیم. این روش معروف به حداقل مربعات تعمیم‌یافته (GLS)^۱ یا حداقل مربعات وزنی (WLS)^۲ است.

به منظور استفاده از روش حداقل مربعات تعمیم‌یافته، مشابه معادله (۴-۳۷) عمل می‌کنیم که طرفین آن را بر عاملی که موجب واریانس ناهمسانی شده است، تقسیم می‌کنیم. در اینجا بحث مذکور را در حالت عمومی به کار می‌بریم. بدین منظور توجه کنیم که اگر ماتریس Ω مثبت معین باشد می‌توان آن را به صورت $\Omega^{-1} = P'P$ نوشت که در اینجا $P = \Omega^{-\frac{1}{2}}$ است. از طرف دیگر، چون Ω متقارن است لذا $P = P'$ است. حال طرفین معادله را در P ضرب می‌کنیم (در واقع آن را بر عامل واریانس ناهمسانی تقسیم کرده‌ایم، زیرا $P = \Omega^{-\frac{1}{2}}$ است).

$$Py = PX\beta + Pu \quad (4-47)$$

مدل فوق را به صورت زیر می‌نویسیم:

$$y_* = X_*\beta + u_* ; y_* = Py, X_* = PX, u_* = Pu \quad (4-48)$$

$$y_* = Py = \begin{bmatrix} \frac{1}{\sigma_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\sigma_2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{1}{\sigma_n} \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \frac{Y_1}{\sigma_1} \\ \frac{Y_2}{\sigma_2} \\ \vdots \\ \frac{Y_n}{\sigma_n} \end{bmatrix}$$

^۱Generalized Least Squares

^۲Weighted Least Squares

$$\begin{aligned}
 \mathbf{X}_* = \mathbf{P}\mathbf{X} &= \begin{bmatrix} \frac{1}{\sigma_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\sigma_v} & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & \frac{1}{\sigma_n} \end{bmatrix} \begin{bmatrix} 1 & X_{v1} & \dots & X_{K1} \\ 1 & X_{v2} & \dots & X_{K2} \\ \vdots & \vdots & & \vdots \\ 0 & X_{vn} & \dots & X_{Kn} \end{bmatrix} = \begin{bmatrix} \frac{1}{\sigma_1} & \frac{X_{v1}}{\sigma_1} & \dots & \frac{X_{K1}}{\sigma_1} \\ \frac{1}{\sigma_v} & \frac{X_{v2}}{\sigma_v} & \dots & \frac{X_{K2}}{\sigma_v} \\ \vdots & \vdots & & \vdots \\ \frac{1}{\sigma_n} & \frac{X_{vn}}{\sigma_n} & \dots & \frac{X_{Kn}}{\sigma_n} \end{bmatrix} \\
 \mathbf{u}_* = \mathbf{P}\mathbf{u} &= \begin{bmatrix} \frac{1}{\sigma_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\sigma_v} & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & \frac{1}{\sigma_n} \end{bmatrix} \begin{bmatrix} u_1 \\ u_v \\ \vdots \\ u_n \end{bmatrix} = \begin{bmatrix} \frac{u_1}{\sigma_1} \\ \frac{u_v}{\sigma_v} \\ \vdots \\ \frac{u_n}{\sigma_n} \end{bmatrix}
 \end{aligned}$$

تخمین $\hat{\beta}$ برای مدل (۴-۴۸) معروف به تخمین‌زننده GLS است که به صورت زیر به دست می‌آید:

$$\begin{aligned}
 \hat{\beta}_{GLS} &= (\mathbf{X}'_* \mathbf{X}_*)^{-1} (\mathbf{X}'_* \mathbf{y}_*) = [(\mathbf{P}\mathbf{X})'(\mathbf{P}\mathbf{X})]^{-1} [(\mathbf{P}\mathbf{X})'(\mathbf{P}\mathbf{y})] \\
 &= (\mathbf{X}'\mathbf{P}'\mathbf{P}\mathbf{X})^{-1} (\mathbf{X}'\mathbf{P}'\mathbf{P}\mathbf{y}) = (\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{X})^{-1} (\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{y})
 \end{aligned} \quad (۴-۴۹)$$

تخمین دو مرحله‌ای

تا اینجا دیدیم که تخمین‌زننده $\hat{\beta}$ در صورت واریانس ناهمسانی برابر با (۴-۴۹) است که $\boldsymbol{\Omega}$ برابر است با:

$$\boldsymbol{\Omega} = \begin{bmatrix} \sigma_1^2 & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \sigma_n^2 \end{bmatrix}$$

استفاده از (۴-۴۹) برای محاسبه $\hat{\beta}$ نیازمند مقادیر \mathbf{X} ، \mathbf{y} و $\boldsymbol{\Omega}$ است. به هر حال مقادیر \mathbf{X} و \mathbf{y} را داریم اما $\boldsymbol{\Omega}$ و عناصر آن یعنی σ_i^2 مجهول است. لذا بایستی تخمین آنها یعنی $\hat{\sigma}_i^2$ را داشته باشیم تا با استفاده از $\hat{\boldsymbol{\Omega}}$ بتوانیم تخمین $\hat{\beta}$ را به دست آوریم. این روش معروف به روش حداقل مربعات تعمیم‌یافته قابل دسترس (FGLS)^۱ است.

^۱Feasible Generalized Least Squares

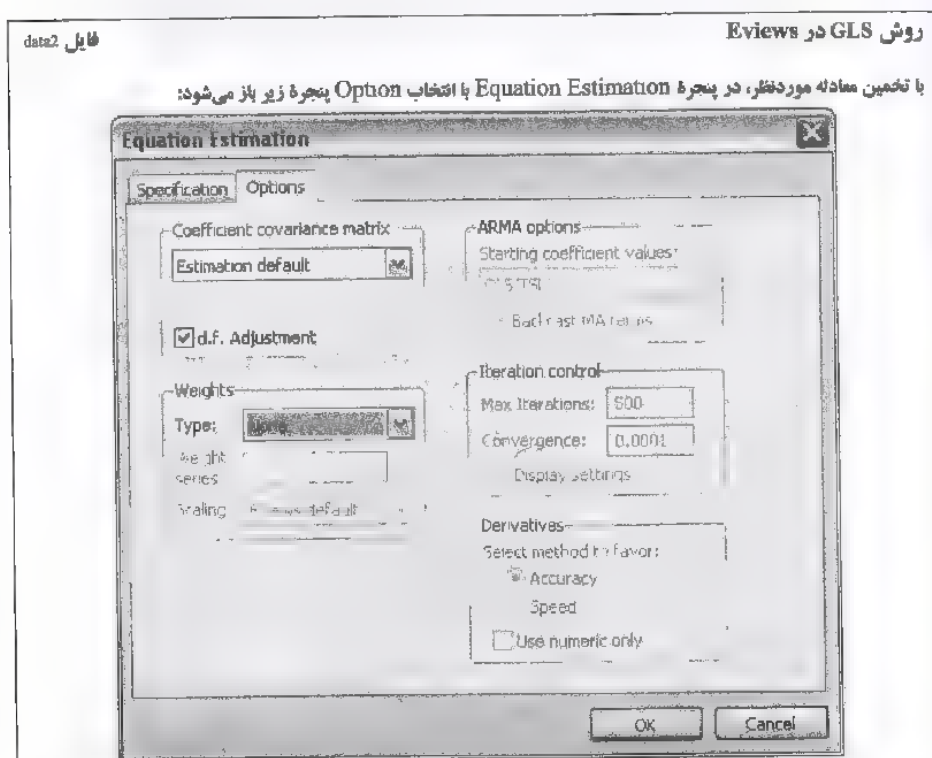
برای محاسبه واریانس‌ها نیاز به باقیمانده‌ها (خطاها) داریم. تصور کنید که $\sigma_i^2 = z_i' \alpha$ است که α بردار ضرایب و z_i بردار متغیرهایی است که موجب واریانس ناهمسانی شده‌اند (z_i ممکن است شامل y_i نیز باشد). در این صورت، ماتریس Ω وابسته به ضرایب α است که بایستی آنها را برآورد کنیم. از طرف دیگر اگر e_i جملات خطای مدل (۴-۳۶) یا (۴-۳۸) باشد، در این صورت، با استفاده از رابطه $E(e_i^2) = \sigma_i^2$ خواهیم داشت:

$$e_i^2 = \sigma_i^2 + v_i = z_i' \alpha + v_i \quad (4-50)$$

با برآورد مدل فوق، $\hat{\alpha}$ به دست می‌آید و با استفاده از $\hat{\sigma}_i^2 = z_i' \hat{\alpha}$ را حساب کرده و ماتریس $\hat{\Omega}$ را تشکیل می‌دهیم. لذا تخمین زنده FGLS عبارت است از:

$$\hat{\beta}_{FGLS} = (X' \hat{\Omega}^{-1} X)^{-1} (X' \hat{\Omega}^{-1} y) \quad (4-51)$$

روش دیگر برای برآورد ضرایب، استفاده از روش حداکثر درستنمایی است که در فصل هفتم بحث شده است.



Inverse std. dev.	
Inverse variance	
Std. deviation	
Variance	

فرض کنید در معادله نرخ رشد تولید داخلی بدون نفت (GYNO) به این نتیجه رسیدیم که دارای واریانس ناهمبانی است. همچنین فرض کنید نتیجه گرفته‌ایم که واریانس ناهمبانی ناشی از متغیر GL است. بدین منظور طریقی معادله را بر GL تقسیم کرده و آن را تخمین می‌دهیم. برای استفاده از روش WLS، متغیر آنچه که گفته شد، در قسمت Weight series عبارت از 1/GL و در قسمت Type گزینه Inverse variance را انتخاب می‌کنیم. نتایج تخمین عبارت است از:

Equation: UNTITLED Workfile: YNO:Untitled

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: GYNO
Method: Least Squares
Date: 01/25/11 Time: 04:14
Sample (adjusted): 1350 1380
Included observations: 25 after adjustments
Weighting series: 1/GL
Weight type: Inverse variance (no scaling)

Variable	Coefficient	Std. Error	t-Statistic	Prob
GL	4.364219	0.342602	3.981932	0.0006
GK	0.202553	0.101589	1.994232	0.0587
BG	0.030358	0.066688	0.441963	0.6628

Weighted Statistics

R-squared	0.502315	Mean dependent var	3.711109
Adjusted R-squared	0.457070	S.D. dependent var	2.730447
S.E. of regression	2.454677	Akaike info criterion	4.748034
Sum squared resid	132.5596	Schwarz criterion	4.892299
Log likelihood	-56.32542	Hannan-Quinn criter.	4.786602
Durbin-Watson stat	0.928161	Weighted mean dep.	4.362945

Unweighted Statistics

R-squared	0.811113	Mean dependent var	7.353841
Adjusted R-squared	0.575760	S.D. dependent var	7.034155
S.E. of regression	4.581606	Sum squared resid	461.8045
Durbin-Watson stat	1.042760		

۴-۴ فرض سوم: عدم خودهمبستگی^۱

عدم خودهمبستگی بین جملات خطای یکی از فروض اساسی برای روش OLS است. همبستگی خطاها با یکدیگر را اصطلاحاً «خودهمبستگی» یا «همبستگی سریالی» می‌گویند. برای بررسی خودهمبستگی، از برآورد خطاها (e_t) استفاده می‌شود. به‌طور کلی خودهمبستگی بیانگر رابطه بین e_t با وقفه‌های آن است.

۴-۴-۱ مفهوم وقفه^۲

مقدار وقفه هر متغیری مانند X_t برابر با مقدار آن در زمان قبلی (X_{t-1}) می‌باشد. به‌عنوان مثال مقادیر X_t و وقفه آن را می‌توان در جدول زیر نشان داد:

زمان	X_t	X_{t-1}	$\Delta X_t = X_t - X_{t-1}$
۱۳۸۰	۱	-	-
۱۳۸۱	۲	۱	۲-۱=۱
۱۳۸۲	۴	۲	۴-۲=۲
۱۳۸۳	-۲	۴	-۲-۴=-۶
۱۳۸۴	-۳	-۲	-۳-(-۲)=-۱
۱۳۸۵	۰	-۳	۰-(-۳)=۳
۱۳۸۶	۵	۰	۵-۰=۵

به‌عنوان مثال در سال ۱۳۸۲، مقدار X در این سال را مقدار جاری و مقدار آن در سال قبل (سال ۱۳۸۱) را مقدار X با «یک وقفه» می‌گویند. تفاضل این دو مقدار (ΔX_t) بیانگر تفاضل مرتبه اول است که مقدار تغییرات X در سال جاری نسبت به سال قبل را نشان می‌دهد.

۴-۴-۱ پیامدهای خودهمبستگی

اگر معادله $Y_t = \alpha + \beta X_t + u_t$ دارای خودهمبستگی به‌صورت $u_t = \rho u_{t-1} + \varepsilon_t$ باشد ولی آن را نادیده بگیریم، پیامدهای زیر را خواهد داشت:

۱- تخمین‌زننده‌های OLS همپتان بدون تورش هستند، زیرا این موضوع مربوط به فرض اول ($E(u_t) = 0$) است که خودهمبستگی موجب نقض آن نمی‌شود.

۲- تخمین‌زننده‌های OLS سازگارند، زیرا این موضوع مربوط به فرض غیرتصادفی بودن X_t یا عدم همبستگی بین u_t و X_t است که خودهمبستگی موجب نقض آن نمی‌شود. این بدان معنا است که با افزایش حجم نمونه، واریانس $\hat{\beta}$ به صفر گرایش دارد.

^۱ autocorrelation

^۲ lag

۳- تخمین زننده OLS کارا نخواهد بود و واریانس $\hat{\beta}$ برابر با $\frac{\sigma^2}{\sum x_i^2}$ نمی باشد، زیرا:

$$\begin{aligned}\text{var}(\hat{\beta}) &= E(\hat{\beta} - \beta)^2 = E\left(\sum_i w_i u_i\right)^2, \quad w_i = \frac{x_i}{\sum x_i^2} \\ &= E\left(\sum_i w_i^2 u_i^2\right) + E\left(\sum_{i \neq s} w_i w_s u_i u_s\right) \\ &= \sum_i w_i^2 E(u_i^2) + 2 \sum_{i \neq s} w_i w_s E(u_i u_s)\end{aligned}$$

با توجه به $E(u_i^2) = \sigma^2$ و $E(u_i u_s) = \rho^{t-s} \sigma^2$ خواهیم داشت (ρ^{t-s} ضریب همبستگی u_t و u_s است):^۱

$$\text{var}(\hat{\beta}) = \frac{\sigma^2}{\sum x_i^2} + 2 \sum_{i \neq s} w_i w_s \rho^{t-s} \sigma^2 \quad (۴-۵۲)$$

بنابراین، واریانس $\hat{\beta}$ برابر با $\frac{\sigma^2}{\sum x_i^2}$ نخواهد بود. لذا برآوردهای OLS منجر به تورش در تخمین واریانس $\hat{\beta}$ می شود که مقدار آن بستگی به حاصل جمع دوم در سمت راست رابطه فوق دارد. اگر u_t ها خودهمبستگی مثبت (یعنی $0 < \rho < 1$) و X_t ها نیز خودهمبستگی مثبت داشته باشند^۲، آنگاه حاصل جمع مذکور، مثبت بوده و لذا واریانس $\hat{\beta}$ در روش OLS کمتر از حد، برآورد می شود. این نیز به نوبه خود موجب بزرگ شدن t ها خواهد شد.

۴-۲-۴ روش های نموداری جهت تشخیص خودهمبستگی

یکی از راه های ساده جهت تشخیص خودهمبستگی، استفاده از نمودار خطاها (e_t) است. بدین منظور برای بررسی رابطه بین e_t و e_{t-1} ، می توان e_t را در مقابل e_{t-1} ترسیم نمود. با ترسیم این داده ها، حالت های مختلفی را می توان مشاهده نمود. به عنوان مثال اگر نموداری مانند (۴-۳) مشاهده کنیم، بیانگر وجود خودهمبستگی مثبت می باشد.^۳

^۱ برای اثبات این رابطه، می توان از تعاریف زیر استفاده نمود:


$$\rho^{t-s} = \frac{\text{cov}(u_t, u_s)}{\sqrt{\text{var}(u_t)} \sqrt{\text{var}(u_s)}} = \frac{E(u_t u_s)}{\sigma^2}$$

زیرا $\text{var}(u_t) = \text{var}(u_s) = \sigma^2$ است. به عنوان مثال $\rho = \frac{E(u_t u_{t-1})}{\sigma^2}$ و $\rho^2 = \frac{E(u_t u_{t-2})}{\sigma^2}$ است.


^۲ این بدان معنا است که $\sum w_t w_s = \frac{\sum x_t x_s}{(\sum x_t^2)^2} > 0$ باشد، زیرا صورت کسر بیانگر $\text{cov}(x_t, x_s)$ است.

^۳ این نمودارها از Brooks (2008) می باشد.


از طرف دیگر اگر مشاهدات مربوط به خطاها (e) را در مقابل زمان ترسیم کنیم، نمودار (۴-۲) به دست خواهد آمد. نمودارهای (۴-۲) و (۴-۳) دقیقاً یکسان هستند. در واقع «خودهمبستگی مثبت» که از نمودار (۴-۳) مشاهده می‌شود، می‌توان آن را در نمودار (۴-۲) به صورت تغییرات منظم e در طول زمان، مشاهده نمود. نمودار (۴-۴) و (۴-۵) خودهمبستگی منفی را نشان می‌دهد.




نمودار ۲-۱: خودهمبستگی مثبت



نمودار ۳: خودهمبستگی مثبت




نمودار ۴-۱: خودهمبستگی منفی




نمودار ۴-۲: خودهمبستگی منفی

بنابراین اگر جملات خطا دارای خودهمبستگی باشند بیانگر این است که در طول زمان به طور منظم تغییر می‌کنند و این در حالی است که بایستی تغییرات آنها کاملاً تصادفی باشد. مثالی از تصادفی بودن جملات خطا در نمودارهای (۴-۶) و (۴-۷) نشان داده شده است. نمودار (۴-۶)

نشان می‌دهد که تغییرات جملات خطا در طول زمان از هیچ قاعده خاصی تبعیت نمی‌کند و کاملاً تصادفی است. نمودار (۴-۷) نیز نشان می‌دهد که بین جملات خطا در دوره فعلی و دوره قبلی هیچ ارتباط خاصی وجود ندارد و اگر بین u_t و u_{t-1} ضریب همبستگی را حساب کنیم و یا رگرسیون بین آنها را برآورد نماییم، هیچ رابطه معناداری به دست نخواهد آمد.



نمودار ۴-۶: عدم خودهمبستگی



نمودار ۴-۷: عدم خودهمبستگی

۳-۴-۴ آزمون دورین-واتسون

قدم اول در شناسایی خودهمبستگی این است که نمودار آنها را به شرحی که گفته شد، ترسیم کنیم. اما در عمل، روش‌های نموداری و تحلیل آنها مشکل است و لذا برخی روش‌های آماری جهت آزمون خودهمبستگی ارائه شده است. یکی از آزمون‌های متداول، آزمون دورین-واتسون (۱۹۵۱) می‌باشد. این آزمون که به اختصار با DW نشان داده می‌شود، برای تشخیص خودهمبستگی مرتبه اول به کار می‌رود، زیرا فقط خودهمبستگی بین مقادیر سال جاری و سال قبل را در نظر می‌گیرد:

$$u_t = \rho u_{t-1} + v_t, \quad v_t \sim N(0, \sigma_v^2) \quad (4-53)$$

در آزمون DW فرضیه‌ها به صورت زیر مطرح می‌شوند:

$$H_0: \rho = 0 \quad \text{عدم خودهمبستگی} \quad (4-54)$$

$$H_1: \rho \neq 0 \quad \text{وجود خودهمبستگی}$$

فرضیه H_0 بیانگر عدم خودهمبستگی است، یعنی خطاهای زمان $t-1$ و t مستقل از هم می‌باشند که در این صورت $u_t = v_t$ بوده و لذا u_t کاملاً تصادفی است. از آنجا که اطلاعاتی راجع به u_t نداریم لذا از برآورد آنها یعنی e_t استفاده می‌کنیم. بر اساس e_t ها، آماره DW به صورت زیر تعریف می‌شود:

$$DW = \frac{\sum_{t=1}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (4-55)$$

در (۴-۵۵) صورت کسر، مقادیر خطا در سال t و سال $t-1$ را مقایسه می‌کند. اگر خطاها دارای خودهمبستگی مثبت باشند، صورت کسر نسبتاً کوچک خواهد شد، زیرا در این حالت، علامت e_t و e_{t-1} تقریباً یکسان بوده (مانند نمودار ۴-۲ و ۴-۳) و تفاضل آنها کوچک خواهد شد. اما اگر خودهمبستگی منفی وجود داشته باشد، صورت کسر نسبتاً بزرگ خواهد شد، زیرا علامت e_t و e_{t-1} تقریباً مخالف می‌باشد (مانند نمودار ۴-۴ و ۴-۵).

برای ساده نمودن DW ، صورت کسر را بازنویسی می‌کنیم:

$$\sum_{t=1}^n (e_t - e_{t-1})^2 = \sum_{t=1}^n e_t^2 + \sum_{t=1}^n e_{t-1}^2 - 2 \sum_{t=1}^n e_t e_{t-1}$$

اما از آنجا که اختلاف چندانی بین $\sum_{t=1}^n e_t^2$ و $\sum_{t=1}^n e_{t-1}^2$ وجود ندارد، لذا تقریباً یکسان هستند:

$$\sum_{t=1}^n e_t^2 = e_1^2 + e_2^2 + \dots + e_n^2 \equiv \sum_{t=1}^n e_{t-1}^2 = e_1^2 + e_2^2 + \dots + e_n^2$$

تفاوت این دو عبارت در این است که اولی e_1^2 و دومی e_n^2 را ندارد. به هر حال با یکسان گرفتن این دو عبارت، خواهیم داشت:

$$DW \equiv \frac{2 \sum_{t=1}^n e_t^2 - 2 \sum_{t=1}^n e_t e_{t-1}}{\sum_{t=1}^n e_t^2} = 2 \left(1 - \frac{\sum_{t=1}^n e_t e_{t-1}}{\sum_{t=1}^n e_t^2} \right)$$

از طرف دیگر، تخمین ρ بر اساس معادله (۴-۲۲) و با استفاده از e_t به جای u_t ، برابر است با:

$$\hat{\rho} = \frac{\sum e_t e_{t-1}}{\sum e_t^2}$$

$\hat{\rho}$ ضریب همبستگی e_t و e_{t-1} را نشان می‌دهد که بر آورد ρ است. حال می‌توان DW را به صورت زیر نوشت:

$$DW \equiv 2(1 - \hat{\rho}) \quad (4-56)$$

طبق (۴-۵۶) اگر $\hat{\rho} = 0$ باشد در این صورت $DW = 2$ است و به معنی عدم خودهمبستگی است. از طرف دیگر اگر $\rho = +1$ باشد به معنی «خودهمبستگی کامل مثبت» است که در این حالت $DW = 0$ می‌باشد. همچنین اگر $\rho = -1$ باشد در این صورت $DW = 4$ می‌باشد که به معنی «خودهمبستگی کامل منفی» است.

اما برای بحث دقیق‌تر راجع به وجود یا عدم وجود خودهمبستگی بایستی مقدار آماره DW را با مقادیر بحرانی مقایسه کنیم. به دلیل اینکه آماره DW رابطه خاصی با توزیع‌های شناخته شده مانند F ، t و χ^2 ندارد، لذا برای DW جداول جداگانه‌ای تشکیل شده است. در این جدول K تعداد

ضرایب به استثنای عرض از مبدأ است و n تعداد مشاهدات می باشد. قضاوت راجع به وضعیت خودهمبستگی طبق نمودار زیر می باشد:

خودهمبستگی منفی (H_1 : رد)	نمی توان نتیجه گیری کرد	عدم خودهمبستگی (H_0 : رد نمی شود)	نمی توان نتیجه گیری کرد	خودهمبستگی مثبت (H_1 : رد)
d_L	d_U	۲	$4 - d_U$	$4 - d_L$

بدین ترتیب اگر DW به اندازه کافی به ۲ نزدیک باشد، به معنی عدم خودهمبستگی است. اما اگر به صفر نزدیک باشد، خودهمبستگی مثبت و اگر به ۴ نزدیک باشد، خودهمبستگی منفی را نشان می دهد.

مثال ۴-۱ فرض کند که مدل زیر با $n=80$ مشاهده برآورد شده است:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t$$

فرض کنید که برای این مدل $DW = 1/25$ به دست آمده باشد. برای قضاوت راجع به خودهمبستگی، مقادیر زیر با توجه به اینکه تعداد ضرایب بالاستثنای عرض از مبدأ برابر ۳ و $n=80$ است، از جدول آماره دوربین-واتسون به دست آمده است:

$$d_L = 1/56 \quad , \quad d_U = 1/72$$

$$4 - d_U = 2/28 \quad , \quad 4 - d_L = 2/44$$

چون $DW = 1/25$ کمتر از $d_L = 1/56$ می باشد لذا این معادله دارای خودهمبستگی مثبت می باشد.

اما برای اینکه آزمون DW معتبر باشد، بایستی شرایط زیر برقرار باشد:

- ۱- معادله رگرسیون بایستی دارای جمله ثابت باشد.
 - ۲- متغیرهای توضیحی بایستی غیرتصادفی باشند.
 - ۳- متغیر وابسته تأخیری نباید در مدل وارد شده باشد.
- در رابطه با مشکل سوم فرض کنید معادله رگرسیون به صورت زیر باشد:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \theta Y_{t-1} + u_t \quad (4-57)$$

در این صورت برای بررسی خودهمبستگی از آماره دیگری به نام h دورین استفاده می‌شود که عبارت است از:

$$h = \hat{\rho} \sqrt{\frac{n}{1 - n \text{var}(\hat{\theta})}} \quad , \quad \hat{\rho} = 1 - \frac{DW}{2} \quad (4-58)$$

برای n های نسبتاً بزرگ، h دارای توزیع نرمال با میانگین ۰ و واریانس ۱ می‌باشد. لذا توزیع h نرمال استاندارد خواهد بود. برای هر توزیع نرمال استاندارد رابطه زیر برقرار است:

$$P(-1/96 \leq h \leq 1/96) = 0/95 \quad (4-59)$$

بنابراین اگر h بین $-1/96$ و $1/96$ قرار بگیرد در این صورت به معنی «عدم خودهمبستگی» است. اگر h کوچکتر از $-1/96$ باشد بیانگر خودهمبستگی منفی و اگر بزرگتر از $1/96$ باشد به معنی خودهمبستگی مثبت است.

مشکل دیگر در خصوص آزمون DW این است که در برخی موارد، مقدار DW در ناحیه عدم تصمیم‌گیری قرار می‌گیرد. در چنین شرایطی ثابت می‌شود که تقریباً d_U مقدار بحرانی جهت معنی‌دار بودن آزمون خودهمبستگی می‌باشد. حالت‌های مختلفی وجود دارد که عبارتند از:

الف) برای آزمون $p=0$ در مقابل $p>0$ اگر $DW < d_U$ باشد، در این صورت $p=0$ در سطح احتمال α رد می‌شود و معادله دارای خودهمبستگی مثبت است.



ب) برای آزمون $p=0$ در مقابل $p<0$ اگر $DW > 4 - d_U$ یا $4 - DW < d_U$ باشد، در این صورت $p=0$ در سطح احتمال α رد می‌شود و خودهمبستگی منفی وجود دارد.



ج) برای آزمون $\rho = 0$ در مقابل $\rho \neq 0$ اگر $DW < d_U$ یا $4 - DW < d_U$ باشد، در این صورت $\rho = 0$ در سطح احتمال 2α رد می‌شود و معادله دارای خودهمبستگی مثبت یا منفی است.^۱



آزمون دورین-واتسون در Eviews

وقتی معادله‌ای با Eviews برآورد می‌شود، همراه با نتایج آن، مقدار آماره DW نیز تحت عنوان Durbin-Watson Stat ارائه می‌دهد. با داشتن مقدار آماره DW و مقایسه آن با مقادیر بحرانی که از جدول مربوطه به دست می‌آید، می‌توان راجع به وجود خودهمبستگی قضاوت نمود.

۴-۴-۴ آزمون بروش-گادفری^۲

به‌خاطر داریم که روش دورین-واتسون برای آزمون خودهمبستگی مرتبه اول است. بنابراین آزمون DW فقط برای شرایط خاص خود قابل کاربرد می‌باشد و اشکال دیگر خودهمبستگی را آزمون نمی‌کند.

به‌عنوان مثال اگر همبستگی بین e_t و e_{t-1} وجود نداشته ولی همبستگی بین e_t و e_{t-2} وجود داشته باشد، در این صورت DW نمی‌تواند هیچ توضیحی راجع به این نوع از خودهمبستگی ارائه نماید. یک راه این است که در محاسبه DW به‌جای e_{t-1} از e_{t-2} استفاده کنیم. در این صورت ضریب همبستگی بین e_t و e_{t-2} محاسبه می‌شود. اما در عمل در نرم‌افزارهای مرسوم، چنین مواردی در نظر گرفته نشده است و همچنین جداولی برای مقادیر بحرانی آن محاسبه نشده است. برای حل مشکل فوق یک آزمون عمومی در نظر گرفته شده که می‌تواند خودهمبستگی مرتبه m را آزمون کند. بدین منظور معادله زیر که خودهمبستگی مرتبه m را نشان می‌دهد، در نظر بگیرید:

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_r u_{t-r} + v_t, \quad v_t \sim N(0, \sigma_v^2) \quad (4-60)$$

فرضیه‌های مورد نظر عبارتند از:

$$H_0: \rho_1 = 0, \rho_2 = 0, \dots, \rho_r = 0 \quad \text{عدم خودهمبستگی} \quad (4-61)$$

$$H_1: \rho_1 \neq 0 \text{ یا } \rho_2 \neq 0 \text{ یا } \dots \text{ یا } \rho_r \neq 0 \quad \text{وجود خودهمبستگی}$$

^۱ Gujarati(2004), P.471

^۲ Breusch-Godfrey

تحت فرضیه H_0 ، خطاهای سال جاری هیچ ارتباطی با r مقادیر قبلی خود ندارند. مراحل انجام این آزمون عبارت است از:

۱- معادله مورد نظر را با روش OLS برآورد می‌کنیم:

$$Y_t = \beta_1 + \beta_2 X_{t-1} + \beta_3 X_{t-2} + \beta_4 X_{t-3} + u_t$$

۲- e_t را حساب کرده و آن را روی متغیرهای توضیحی و خطاهای تأخیری برازش کرده و R^2 آن را حساب می‌کنیم:

$$e_t = \alpha_1 + \alpha_2 X_{t-1} + \alpha_3 X_{t-2} + \alpha_4 X_{t-3} + \rho_1 e_{t-1} + \dots + \rho_r e_{t-r} + v_t \quad (4-62)$$

اگر تعداد مشاهدات برابر با n باشد، در این صورت می‌توان برای آزمون این فرضیه از χ^2 استفاده نمود:

$$(n-r)R^2 \sim \chi^2_r \quad (4-63)$$

توجه شود که در اینجا تعداد مشاهدات برای برآورد معادله e_t فقط $n-r$ می‌باشد. اگر مقدار آماره $(n-r)R^2$ بزرگتر از مقدار بحرانی (که از جدول به دست می‌آید) باشد، در این صورت فرضیه H_0 رد می‌شود و معادله رگرسیون دارای خودهمبستگی است. هر چند آزمون بروش-گادفری عمومی‌تر از آزمون DW است ولی مشکل آن در تعیین r یعنی تعداد وقفه‌ها، است.

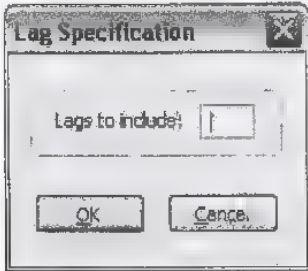
آزمون بروش-گادفری در Eviews

فایل data2

برای انجام آزمون بروش-گادفری جهت شناسایی خودهمبستگی، ابتدا معادله مورد نظر را تخمین می‌زنیم. سپس در پنجره‌ای که نتایج تخمین نشان داده شده است (پنجره Equation) مسیر زیر را انتخاب می‌کنیم:

View → Residual Diagnostic → Serial Correlation LM Test

در این حالت پنجره Lag Specification باز می‌شود:



که بایستی تعداد وقفه‌ها (r) را به آن بدهیم. با انتخاب OK، معادله e_t یعنی معادله ۲-۴ برآورد می‌شود.

Equation: UNTITLED Workfile: VNO:Untitled									
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Breusch-Godfrey Serial Correlation LM Test									
F-statistic	0.641424		Prob F(2,30)		0.5336				
Obs*R-squared	1.435281		Prob Chi-Square(2)		0.4879				
Test Equation:									
Dependent Variable: RES.D									
Method: Least Squares									
Date: 01/25/11 Time: 05:18									
Sample: 1346 1380									
Included observations: 35									
Presample missing value lagged residuals set to zero.									
Variable	Coefficient	Std. Error	t-Statistic	Prob.					
C	0.110183	1.001510	0.110017	0.9131					
GL	-0.017235	0.186703	-0.092311	0.9271					
GK	-0.009106	0.093942	-0.096837	0.9234					
RESID(-1)	0.209243	0.186655	1.121017	0.2712					
RESID(-2)	-0.054389	0.201551	-0.269852	0.7891					
R-squared	0.041008	Mean dependent var	1.32E-15						
Adjusted R-squared	-0.086858	S.D. dependent var	4.129714						
S.E. of regression	4.305328	Akaike info criterion	5.889148						
Sum squared resid	556.0756	Schwarz criterion	8.111340						
Log likelihood	-98.06038	Hannan-Quinn criter	5.985848						
F-statistic	0.320712	Durbin-Watson stat	1.925825						
Prob(F-statistic)	0.861846								

در اینجا نیز مجدداً مقادیر F و $(n-r)R^2$ با احتمال‌های مربوطه نشان می‌دهد که این مدل خودهمبستگی ندارد، مقدار F و همچنین $(n-r)R^2 = 32(0.041) = 1.32$ کوچک هستند و در ناحیه بحرانی قرار ندارند و لذا فرضیه H_0 رد نمی‌شود.

۴-۴-۵ پیامد نادیده گرفتن خودهمبستگی

اگر خودهمبستگی وجود داشته باشد ولی آن را نادیده بگیریم، تخمین ضرایب بدون تورش ولی ناکارآ می‌باشند. این ناکارایی حتی در نمونه‌های بزرگ نیز از بین نمی‌رود و انحراف معیارها دارای خطا می‌باشند.^۱ این امر منجر به استنتاج‌های نادرست می‌شود. در حالتی که خودهمبستگی

۱- به عنوان مثال در $Y_t = \alpha + \beta_1 X_t + u_t$ که u_t خود همبستگی مرتبه اول به شکل $u_t = \rho u_{t-1} + \varepsilon_t$ دارد، در این

حالت تخمین زننده OLS برای β که به صورت $\hat{\beta} = \frac{\sum x_t y_t}{\sum x_t^2}$ است، دارای واریانس زیر می‌باشد:

$$\text{var}(\hat{\beta}) = \frac{\sigma^2}{\sum x_t^2} + \frac{\sigma^2}{(\sum x_t^2)^2} \left(\rho \sum_{t=1}^{n-1} x_t x_{t+1} + \rho^2 \sum_{t=1}^{n-2} x_t x_{t+2} + \dots + \rho^{n-1} x_1 x_n \right)$$

مثبت وجود داشته باشد انحراف معیارها کمتر از حد واقعی برآورد می‌شوند. بدین معنی که در این حالت، روش OLS انحراف معیار را کم برآورد می‌کند. در نتیجه موجب افزایش t ها شده و ضرایب برآورد شده گرایش به معنادار شدن دارند و لذا مرتکب خطای نوع اول (رد H_0 در حالی که H_0 یک فرضیه درست است) می‌شویم. علاوه بر این، اگر خودهمبستگی مثبت وجود داشته باشد و آن را نادیده بگیریم به احتمال زیاد منجر به افزایش مقدار R^2 می‌شود زیرا خودهمبستگی، مقدار واریانس جمله خطا را کم برآورد می‌کند.

۴-۴-۶ تخمین ضرایب در حالت خودهمبستگی

اگر شکل خودهمبستگی را بدانیم می‌توان به سادگی از روش OLS استفاده نمود. یکی از روش‌های شناخته شده برای تخمین ضرایب در حالت خودهمبستگی، روش کوکران-اورکات^۱ می‌باشد. این روش معمولاً برای خودهمبستگی مرتبه اول طرح شده است. بدین منظور مدل زیر را در نظر بگیرید که در آن u_t دارای خودهمبستگی مرتبه اول است:

$$Y_t = \beta_1 + \beta_2 X_t + u_t \quad (4-64)$$

$$u_t = \rho u_{t-1} + v_t \quad (4-65)$$

فرض کنید که u_t دارای میانگین صفر باشد. مدل فوق را با یک دوره تأخیر نوشته و در ρ ضرب می‌کنیم:

$$\rho Y_{t-1} = \rho \beta_1 + \rho \beta_2 X_{t-1} + \rho u_{t-1} \quad (4-66)$$

حال (۴-۶۶) را از (۴-۶۴) کم می‌کنیم:

$$Y_t - \rho Y_{t-1} = \beta_1(1 - \rho) + \beta_2(X_t - \rho X_{t-1}) + (u_t - \rho u_{t-1}) \quad (4-67)$$

در (۴-۶۷) به جای پرانتز آخر از رابطه (۴-۶۵) قرار می‌دهیم:

$$Y_t - \rho Y_{t-1} = \beta_1(1 - \rho) + \beta_2(X_t - \rho X_{t-1}) + v_t \quad (4-68)$$

با تعریف $Y_t^* = Y_t - \rho Y_{t-1}$ ، $\beta_1^* = \beta_1(1 - \rho)$ و $X_t^* = X_t - \rho X_{t-1}$ ، معادله (۴-۶۸) را به صورت زیر می‌نویسیم:

$$Y_t^* = \beta_1^* + \beta_2 X_t^* + v_t \quad (4-69)$$

¹ Cocran-Orkat

از آنجا که مدل (۴-۶۹) خود همبستگی ندارد، لذا می‌توان آن را با روش OLS تخمین زد. اما مدل (۴-۶۹) مبتنی بر داده‌های جدیدی است که به صورت Y_i^* و X_i^* هستند. محاسبه چنین داده‌هایی نیاز به مقدار $\hat{\rho}$ دارد. در عمل مقدار ρ معلوم نیست. یکی از روش‌های ساده این است که ابتدا با تخمین مدل (۴-۶۴) مقدار DW را به دست آورده و با استفاده از رابطه $DW = 2(1 - \hat{\rho})$ ، مقدار $\hat{\rho}$ را حساب نمود. سپس بر اساس $\hat{\rho}$ ، مقادیر جدید یعنی X_i^* و Y_i^* را محاسبه نموده و آنگاه مدل (۴-۶۹) را با روش OLS برآورد نمائیم. روش تکراری کوکران-اورکات یکی از روش‌های متداول است که مراحل آن به صورت زیر است:

۱- ابتدا معادله $Y_i = \beta_1 + \beta_2 X_i + u_i$ را با روش OLS برآورد کرده و باقیمانده‌ها (\hat{u}_i یا e_i) را حساب می‌کنیم.

۲- بر اساس باقیمانده‌های مرحله اول، مدل $\hat{u}_i = \rho \hat{u}_{i-1} + v_i$ یا $e_i = \rho e_{i-1} + v_i$ را برآورد می‌کنیم که تخمین $\hat{\rho}$ به دست می‌آید:

$$\hat{\rho} = \frac{\sum e_{i-1} e_i}{\sum e_i^2} \quad (4-70)$$

۳- با استفاده از $\hat{\rho}$ مقادیر X_i^* و Y_i^* را حساب کرده و سپس روش OLS را برای تخمین مدل (۴-۳۹) به کار می‌بریم.

۴- تکرار مراحل ۲ و ۳ در اینجا ابتدا در مرحله ۳ مقادیر خطاها را حساب کرده و مجدداً مرحله ۲ را تکرار می‌کنیم تا به تخمین جدیدی از $\hat{\rho}$ برسیم و سپس با $\hat{\rho}$ جدید به مقادیر جدیدی برای X_i^* و Y_i^* می‌رسیم و بر اساس آنها مجدداً مدل (۴-۵۹) را برآورد می‌کنیم. این تکرارها تا جایی ادامه می‌یابد که مقدار $\hat{\rho}$ تقریباً ثابت بماند و با تکرار مرحله بعدی، تغییر محسوسی در آن ایجاد نشود. در چنین شرایطی معمولاً عدد کوچکی را برای همگرایی $\hat{\rho}$ در نظر می‌گیرند. مثلاً اگر از یک مرحله به مرحله دیگر تغییرات $\hat{\rho}$ کمتر از ۰/۰۰۱ باشد، در این صورت $\hat{\rho}$ تقریباً به مقدار ثابتی رسیده است. اگر مقدار $\hat{\rho}$ در مرحله m با $\hat{\rho}_m$ و در مرحله $m+1$ با $\hat{\rho}_{m+1}$ نشان دهیم، در این صورت هدف این است که تکرارها تا جایی ادامه یابد که شرط $|\hat{\rho}_m - \hat{\rho}_{m+1}| < 0/001$ تأمین شود.

نگاه دیگر به موضوع خودهمبستگی این است که آن را به جای یک «مشکل»، یک «فرصت» می‌داند. بدین معنی که «وجود خودهمبستگی» به معنی یک «اطلاعات مهم» است و این نشان از تصریح نامناسب مدل دارد. وقتی Y_t ها همبستگی داشته باشند، بدان معنا است که مدل‌سازی Y_t مناسب نبوده است و ساختار پویای آن را در نظر نگرفته‌ایم. در واقع در داخل Y_t ها عامل یا متغیری وجود دارد که باعث همبستگی سریالی بین آنها شده است و لذا به جای رفع خودهمبستگی، باید مدل‌سازی Y_t را تغییر داده و آن را پویا نماییم.

۴-۶-۲ خودهمبستگی و مدل‌های پویا

مدل‌ها که تاکنون بررسی نمودیم مدل‌های ایستا هستند. به عنوان مثال مدل ایستای یک متغیره عبارت است از:

$$Y_t = \beta_0 + \beta_1 X_t + u_t \quad (4-71)$$

مدل (۴-۷۱) بیانگر یک رابطه ایستا و آنی بین متغیرهاست به گونه‌ای که اگر X در زمان t تغییر کند منجر به تغییر آنی در Y خواهد شد. اما این تحلیل را می‌توان به صورت پویا بیان نمود و مدل (۴-۷۱) را به صورت زیر نوشت که مشابه مدل (۴-۶۸) می‌باشد:

$$Y_t = \beta_0 + \beta_1 X_t + \gamma_1 Y_{t-1} + \gamma_2 Y_{t-2} + u_t \quad (4-72)$$

در مدل (۴-۷۲) علاوه بر رابطه بین مقدار جاری متغیرها، بین مقدار آنها در طی زمان‌های مختلف نیز ارتباط برقرار شده است. به گونه‌ای که اگر X در سال $t-1$ تغییر کند، هم بر Y در سال t و هم بر Y در سال $t-1$ اثر خواهد گذاشت. برای بررسی این اثرات، می‌توان معادله (۴-۷۲) را به صورت زیر نوشت:

$$Y_{t-1} = \beta_0 + \beta_1 X_{t-1} + \gamma_1 Y_{t-2} + \gamma_2 Y_{t-3} + u_{t-1} \quad (4-73)$$

$$Y_t = \beta_0 + \beta_1 X_t + \gamma_1 X_{t-1} + \gamma_2 Y_{t-1} + u_t \quad (4-74)$$

$$Y_{t+1} = \beta_0 + \beta_1 X_{t+1} + \gamma_1 X_t + \gamma_2 Y_t + u_{t+1} \quad (4-75)$$

$$Y_{t+2} = \beta_0 + \beta_1 X_{t+2} + \gamma_1 X_{t+1} + \gamma_2 Y_{t+1} + u_{t+2} \quad (4-76)$$

اگر X_{t-1} تغییر کند طبق معادله (۴-۷۳) بر Y_{t-1} اثر می‌گذارد. از طرف دیگر طبق معادله (۴-۷۴) هم X_{t-1} و هم Y_{t-1} بر Y_t اثر می‌گذارند. همچنین طبق معادله (۴-۷۵)، تغییرات Y_t بر Y_{t+1} اثر می‌گذارد. این تغییرات همچنان ادامه می‌یابد.

مدل‌هایی که فقط شامل متغیرهای توضیحی تأخیری باشند موسوم به مدل‌های باوقفه توزیعی^۱ هستند. اما مدل‌ها که در آنها هم متغیر توضیحی و هم متغیر وابسته دارای وقفه باشند، موسوم به مدل‌های باوقفه توزیعی خودرگرسیون (ARDL)^۲ می‌باشند که در فصل دهم بررسی شده‌اند.

حال سؤال این است که چرا باید وقفه‌ها را وارد یک مدل کنیم؟

مقادیر باوقفه متغیرهای توضیحی یا متغیر وابسته به معنی این است که ساختار مدل، پویا می‌باشد. یکی از دلایل مهمی که در این زمینه وجود دارد، کندی تعدیل متغیر وابسته است. اغلب اوقات تغییرات متغیر توضیحی اثر خود را به‌طور آنی بر متغیر وابسته نمی‌گذارد، بلکه اثرات آن نیاز به گذشت زمان دارد. به‌عنوان مثال تغییر در سیاست دولت ممکن است نیاز به گذشت چند ماه یا سال داشته باشد تا بتواند اثرات خود را بر متغیرهای اقتصادی بگذارد. همچنین در بازارهای مالی مانند بورس وقتی تغییری رخ می‌دهد و به‌صورت اطلاعات جدید دریافت می‌شود، ممکن است افراد به‌طور آنی به آن واکنش نشان ندهند، بلکه به‌صورت تدریجی خود را با آن تطبیق دهند. سرعت و مقدار واکنش آنها همچنین بستگی به این دارد که آیا آنها تغییرات را دائمی می‌دانند یا موقتی. همچنین تأخیر در واکنش ممکن است ناشی از عوامل نهادی و فنی باشد. به‌عنوان مثال وجود فناوری‌های پیشرفته می‌تواند به سرعت خرید و فروش سهام کمک نماید و از این رو واکنش‌ها را سریع‌تر می‌نماید.

خودهمبستگی و مدل‌های پویا در Eviews

فایل data

در Eviews می‌توان متغیرهای X_t ، X_{t-1} ، X_{t-2} ، X_{t-3} و به‌عنوان متغیر توضیحی به مدل مورد نظر اضافه نمود. در این حالت آنها را به‌صورت X ، $X(-1)$ ، $X(-2)$ و $X(-3)$ وارد معادله می‌کنیم. اگر سرمایه‌گذاری خصوصی (IP) را روی نرخ بهره حقیقی (RR) برازش کنیم، این معادله با اجرایی فرمان LS IP C RR برآورد می‌شود که نتایج آن عبارت است از:

^۱ Distributed lag

^۲ Autoregressive Distributed Lag

Equation: UNTITLED Workfile: S3: Untitled					
View	Proc	Object	Print	Name	Freeze
Estimate	Forecast	Stats	Resids		
Dependent Variable: IP					
Method: Least Squares					
Date: 01/25/11 Time: 06:00					
Sample: 1345 1375					
Included observations: 31					
Variable	Coefficient	Std. Error	t-Statistic	Prob.	
C	20571.71	2295.986	8.959940	0.0000	
RR	-427.0836	209.5619	2.037789	0.0508	
R-squared	0.126267	Mean dependent var	23205.95		
Adjusted R-squared	0.095093	S.D. dependent var	11106.10		
S.E. of regression	10564.86	Akaike info criterion	21.43079		
Sum squared resid	3.24E+09	Schwarz criterion	21.52331		
Log likelihood	-330.1773	Hannan-Quinn criter.	21.46095		
F-statistic	4.152584	Durbin-Watson stat	0.812045		
Prob(F-statistic)	0.050785				

از آنجا که $DW=0.81$ می باشد، لذا این معادله دارای خودهمبستگی است. همان طور که اشاره شد، خودهمبستگی یکی از علائم نادرست بودن مدل است. حال مدل را به صورت پویا در نظر گرفته و متغیر وابسته تأخیری را به آن اضافه می کنیم، برای برآورد این مدل فرمان زیر را اجرا می کنیم:

$$LS \quad IP \quad C \quad RR \quad IP(-1)$$

نتیجه حاصله عبارت است از:

Equation: UNTITLED Workfile: S3: Untitled					
View	Proc	Object	Print	Name	Freeze
Estimate	Forecast	Stats	Resids		
Dependent Variable: IP					
Method: Least Squares					
Date: 01/25/11 Time: 06:07					
Sample (adjusted): 1346 1375					
Included observations: 30 after adjustments					
Variable	Coefficient	Std. Error	t-Statistic	Prob.	
C	7229.382	3132.899	2.307563	0.0289	
RR	41.49133	168.3648	0.246437	0.8072	
IP(-1)	0.736791	0.137058	5.375770	0.0000	
R-squared	0.561056	Mean dependent var	23818.94		
Adjusted R-squared	0.528541	S.D. dependent var	10752.83		
S.E. of regression	7383.198	Akaike info criterion	20.74644		
Sum squared resid	1.47E+08	Schwarz criterion	20.88656		
Log likelihood	-308.1966	Hannan-Quinn criter.	20.78127		
F-statistic	17.25560	Durbin-Watson stat	2.228264		
Prob(F-statistic)	0.000015				

برای بررسی خودهمبستگی از h دورین استفاده می کنیم، زیرا این مدل دارای متغیر وابسته تأخیری است:

$$h = \left(1 - \frac{DW}{2}\right) \sqrt{\frac{n}{1 - n \text{var}(\hat{\theta})}} = \left(1 - \frac{2/24}{2}\right) \sqrt{\frac{30}{1 - (2)(0.137)^2}} = -1.9795$$

چون مقدار -1.9795 در فاصله $(1/96 \text{ و } -1/96)$ قرار دارد، لذا وجود خودهمبستگی رد می شود.

۸-۱-۱ خودهمبستگی و فرایندهای خودرگرسیون (AR)^۱ و میانگین متحرک (MA)^۲ فرایند خودهمبستگی مرتبه اول که به شکل $u_t = \rho u_{t-1} + \varepsilon_t$ است را $AR(1)$ می‌گویند که معروف به خودرگرسیون مرتبه اول است. همچنین $u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \varepsilon_t$ را فرایند $AR(2)$ می‌گویند که بیانگر خودهمبستگی مرتبه دوم است. اما نوع دیگری از این فرایندها را می‌توان تعریف کرد که معروف به میانگین متحرک (MA) هستند. به‌عنوان مثال اگر خودهمبستگی به شکل $u_t = \varepsilon_t + \theta \varepsilon_{t-1}$ باشد آن را میانگین متحرک مرتبه اول می‌گویند که با $MA(1)$ نشان داده می‌شود. اینکه چگونه فرایند MA بیانگر خودهمبستگی است، می‌توان آن را به AR تبدیل نمود. همچنین می‌توان فرایند AR نیز تحت شرایطی، تبدیل به MA نمود. قابلیت تبدیل این فرایندها و جزئیات آن در فصل یازدهم بحث شده است. به‌عنوان مثال می‌توان $AR(1)$ را به صورت $u_t = \varepsilon_t + \phi \varepsilon_{t-1} + \phi^2 \varepsilon_{t-2} + \dots$ نوشت که بیانگر $MA(\infty)$ است. علاوه بر نکات فوق، در معادله $u_t = \rho u_{t-1} + \varepsilon_t$ ، اگر $\rho = -1$ باشد، آنگاه معادله (۴-۶۷) را به صورت زیر می‌توان نوشت:

$$Y_t + Y_{t-1} = \beta_1 + \beta_2 (X_t + X_{t-1}) + (u_t + u_{t-1})$$

با تقسیم طرفین بر ۲ خواهیم داشت:

$$\frac{Y_t + Y_{t-1}}{2} = \beta_1 + \beta_2 \frac{X_t + X_{t-1}}{2} + \frac{u_t + u_{t-1}}{2} \quad (4-67)$$

معادله فوق بیانگر میانگین متحرک متغیرها است.

به‌مرحال، نتیجه کلی بحث فوق آن است که اگر معادله رگرسیون دارای خودهمبستگی باشد، ممکن است از یکی از فرایندهای AR یا MA تبعیت کند و لذا برای حل مشکل خودهمبستگی می‌توان فرایندهای AR یا MA را در نظر گرفت.

رفع خودهمبستگی با استفاده از AR و MA در Eviews

در Eviews می‌توان معادله رگرسیون را همراه با AR و MA تخمین زد. به‌عنوان مثال برای رفع خودهمبستگی مرتبه اول می‌توان فرایند $AR(1)$ را در نظر گرفت و با فرمان $LS Y C X AR(1)$ آن را تخمین زد. همچنین برای $MA(1)$ از فرمان $LS Y C X MA(1)$ استفاده می‌شود. علاوه بر این، می‌توان هر دو را با فرمان $LS Y C X AR(1) MA(1)$ برآورد نمود.

^۱Autoregressive

^۲Moving Average

۵-۴ فرض ۴: غیر تصادفی بودن متغیرهای توضیحی

غیر تصادفی بودن متغیرهای تصادفی (X_i ها) یکی از فروض کلاسیک است که موجب می شود تا تخمین زنده های OLS بدون تورش باشند. غیر تصادفی بودن X_i موجب استقلال آن از متغیر تصادفی u_i می گردد. اما اگر X_i تصادفی باشد، تخمین زنده های OLS مجدداً سازگار و بدون تورش خواهند بود. بدین منظور تخمین زنده OLS را در نظر بگیرید که عبارت است از:

$$\hat{\beta} = (X'X)^{-1}(X'y) = \beta + (X'X)^{-1}X'u \quad (4-78)$$


امید ریاضی $\hat{\beta}$ عبارت است از:

$$E(\hat{\beta}) = \beta + (X'X)^{-1}E(X'u) \quad (4-79)$$

برای آنکه $\hat{\beta}$ بدون تورش باشد، لازم است که X و u مستقل باشند، هرچند که X تصادفی باشد.


با فرض مستقل بودن X و u ، رابطه $E(X'u) = E(X')E(u) = 0$ برقرار است و لذا $\hat{\beta}$ بدون تورش خواهد بود. اما مشکل زمانی به وجود می آید که X و u مستقل نباشند. در این صورت $E(X'u) \neq 0$ است و لذا $\hat{\beta}$ تخمین زنده بدون تورش نخواهد بود.

همبستگی بین u_i و X_i می تواند ناشی از عوامل مختلفی باشد. به عنوان مثال اگر مشاهدات Y و X مانند نمودار زیر باشد، در این صورت رگرسیون دچار شکستگی شده است (فصل ششم را ببینید) و بدون توجه به آن، رگرسیون را برآورد کرده ایم.



نمودار ۸-۴

با ترسیم خط رگرسیون، وضعیت باقیمانده‌ها روشن‌تر می‌شود.



نمودار ۹-۴: همبستگی مثبت بین X و u


نمودار فوق نشان می‌دهد که با افزایش X مقادیر جمله خطا افزایش می‌یابد، زیرا به ازای X_i های کوچک، u_i ها منفی هستند و به ازای X_i های بزرگ، u_i ها مثبت می‌باشند. این مثالی از همبستگی مثبت بین X و u است.

۴-۶ فرض ۵: فرض نرمال بودن u_i

یکی از فروض مربوط به جمله خطاها این است که u_i توزیع نرمال دارد.


$$u_i \sim N(0, \sigma^2) \quad (4-80)$$

به خاطر داریم که تمام آزمون‌های مربوط به معنادار بودن ضرایب مبتنی بر فرض نرمال بودن u_i است. اگر u_i دارای توزیع نرمال با میانگین صفر باشد، آنگاه در اطراف میانگین خود به صورت متقارن توزیع می‌شود.



نمودار ۱۰-۴: توزیع متقارن

اما اگر u_t نرمال نباشد، ممکن است قرینه نباشد و دارای چولگی باشد.



نمودار ۱۱-۱: توزیع‌های نامتقارن (چوله)

از طرف دیگر $\frac{u_t - E(u_t)}{\sigma} = \frac{u_t}{\sigma}$ توزیع نرمال استاندارد با میانگین صفر و واریانس ۱ دارد. هر توزیع نرمال استاندارد اولاً قرینه است، یعنی ضریب چولگی آن صفر است و ثانیاً ضریب کشیدگی آن برابر با ۳ می‌باشد. بنابراین، برای بررسی انحراف از توزیع نرمال، بایستی ضرایب چولگی و کشیدگی را محاسبه و بررسی نماییم.

جارکیو و برا^۱ (۱۹۸۱) ایده فوق را در قالب یک آزمون ارائه نمودند. برای متغیر تصادفی u با امید ریاضی صفر و واریانس σ^2 ، ضرایب چولگی (A_1) و کشیدگی (A_2) عبارتند از:

$$A_1 = \frac{E(u_t^3)}{\sigma^3}, \quad A_2 = \frac{E(u_t^4)}{\sigma^4} \quad (۴-۵۱)$$

اگر u_t قرینه باشد، آنگاه A_1 تقریباً صفر است. همچنین اگر A_2 نزدیک به ۳ باشد در این صورت کشیدگی u_t به نرمال استاندارد نزدیک است و $A_2 - 3$ نیز تقریباً صفر خواهد بود. بنابراین، اگر u_t نرمال باشد A_2 و $A_2 - 3$ تقریباً صفر خواهند بود. بر این اساس، آماره جارکیو-برا برای آزمون نرمال بودن عبارت است از:

$$JB = n \left(\frac{A_1^2}{6} + \frac{(A_2 - 3)^2}{24} \right) \quad (۴-۵۲)$$

¹ Jarque and Bera

تابع JB تحت فرضیه H (فرضیه‌ای که طبق آن، u نرمال است) به توزیع χ^2 با درجه آزادی ۲ گرایش دارد که مقدار بحرانی آن برابر با $\chi^2_{0.05,2} = 5.99$ است. برای محاسبه JB می‌توان A_t و A_{t-1} را با استفاده از e_t ‌ها محاسبه نمود. بدین منظور بایستی $E(u_t^2)$ و $E(u_t)$ و همچنین $E(u_t) = \sigma^2$ را برآورد نماییم. تخمین $E(u_t^2)$ و $E(u_t)$ برابر است با:

$$\hat{E}(u_t^2) = \frac{\sum_{t=1}^n e_t^2}{n} \quad (4-53)$$

$$\hat{E}(u_t) = \frac{\sum_{t=1}^n e_t}{n}$$

اگر A_t یا A_{t-1} و یا هر دو آنها بزرگ باشند، آنگاه مقدار χ^2 را افزایش داده و در ناحیه بحرانی قرار می‌گیرد که فرضیه H (نرمال بودن e_t) را رد می‌کند و بدین معنی است که u_t از نظر چولگی یا کشیدگی، اختلاف زیادی با توزیع نرمال دارد.

فایل data2


آزمون نرمال بودن با استفاده از Eviews

برای آزمون نرمال بودن ابتدا معادله اصلی را برآورد کرده و سپس در پنجره‌ای که نتایج تخمین را نشان می‌دهد، به صورت زیر عمل می‌کنیم:

View → Residual Diagnostics → Histogram–Normality Test

اگر بالیمانده‌ها به صورت نرمال توزیع شده باشند، نمودار آن تقریباً به صورت نرمال است و آماره JB معنی‌دار نمی‌باشد. این بدان معنا است که در چنین شرایطی مقدار آماره JB کوچک می‌باشد و مقدار احتمال که در زیر آماره JB داده می‌شود، بزرگتر از ۰/۰۵ است. در واقع بزرگ بودن احتمال معادل با کوچک بودن آماره JB است که در این صورت فرضیه نرمال بودن رد نمی‌شود. بر عکس اگر مقدار احتمال کوچک باشد مقدار آماره JB بزرگ خواهد بود و لذا فرضیه نرمال بودن رد می‌شود. به طور کلی اگر $JB > 5.99$ باشد، نرمال بودن رد می‌شود، در این صورت مقدار احتمال که در زیر آماره JB داده می‌شود کوچکتر از ۰/۰۵ خواهد بود.

به عنوان مثال در رگرسیون نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) روی رشد نیروی کار (GL) و رشد سرمایه (GK)، نتایج آن در پنجره Equation نشان داده می‌شود. در این پنجره از منوی View آزمون نرمال بودن را بررسی می‌کنیم که نتایج عبارت است از:



نمودار ۱۲-۱: مشاهدات دورافتاده

وجود مشاهدات دورافتاده موجب کشیدگی بیش از حد می‌شود و لذا آن را تبدیل به یک توزیع دم‌پهن می‌کند. این پدیده‌های است که در داده‌های بورس معمولاً مشاهده می‌شود. مشاهدات دورافتاده به دلیل وقوع حوادث نادر^۱ یا به هر دلیل دیگری به وجود می‌آید. یکی از راه‌حل‌های این پدیده، استفاده از متغیرهای مجازی^۲ است. جزئیات این بحث در فصل پنجم ارائه شده است. کارکرد متغیرهای مجازی بدین صورت است که می‌تواند اثر مشاهدات دورافتاده را به صورت جداگانه لحاظ کند و تأثیر آنها را بر باقیمانده‌ها (e_i) حذف نماید. به عنوان مثال فرض کنید که دوره ۸۰-۱۳۵۰ را بررسی می‌کنیم. در یکی از این سالها مثلاً در سال ۱۳۵۷ مقدار متغیر مورد نظر تفاوت فاحشی با بقیه سال‌ها دارد. در اینجا یک متغیر جدید (مثلاً به نام D57) معرفی می‌کنیم که مقدار آن برای سال ۱۳۵۷ برابر با ۱ و برای بقیه سال‌ها برابر با صفر است. در این حالت در مدل جدید، اثر مشاهده سال ۱۳۵۷ بر روی باقیمانده‌ها تعدیل می‌شود و موجب می‌شود تا باقیمانده‌ها دارای توزیع نرمال باشند.

مسائل

۱- ثابت کنید اگر رگرسیون بدون عرض از مبدأ برآورد شود، مجموع پسماندها لزوماً صفر

نخواهد بود. اگر $R^2 = 1 - \frac{\sum e_i^2}{\sum y_i^2}$ را حساب کنیم، ممکن است منفی شود.

^۱rare events

^۲dummy variables

۲- نمونه ۵ تایی زیر را داریم:

X	۴	۲	۵	۸	۲
Y	۶	۳	۱۲	۱۵	۴

با فرض اینکه واریانس ناهمسانی از نوع $\sigma^2 X_i = \sigma^2$ باشد، برآوردهای α ، β و انحراف معیار معیار آنها را با روش GLS به دست آورید.

۳- مواردی را که آزمون دوربین- واتسون قابل کاربرد نیست نام برده و توضیح دهید.

۴- برای بررسی واریانس ناهمسانی، معادله زیر معرفی شده است. آیا می توان پارامترها را به روش OLS تخمین زد؟

$$|u_i| = \sqrt{\alpha + \beta X_i} + \varepsilon_i$$

اگر جواب منفی است آیا روشی برای تخمین این پارامترها وجود دارد؟

۵- گفته می شود که مدل های لگاریتمی توانایی کاهش مسئله واریانس ناهمسانی را دارند.

برای مثال مدل $Y_i = \alpha X_i^\beta u_i$ زیر را در نظر بگیرید که می توان آن را به صورت زیر نوشت:

$$\ln Y_i = \alpha + \beta \ln X_i + \ln u_i, \quad \alpha = \ln a$$

الف) اگر بخواهیم امید ریاضی $\ln u_i$ صفر باشد، u_i چه توزیعی باید داشته باشد؟

ب) اگر $E(u_i) = 1$ باشد، آیا $E(\ln u_i)$ می تواند صفر باشد؟

ج) اگر $E(\ln u_i)$ صفر نباشد برای آنکه صفر شود چه می توان کرد؟

۶- معادله رگرسیون زیر را در نظر بگیرید:

$$\hat{Y}_i = 2/55 + 0/65 Y_{i-1} + 3/42 X_i; \quad n=50, \quad DW=1/65$$

(۲/۲) (۵/۵) (۳/۱)

اعداد داخل پرانتز مقادیر t هستند. خودهمبستگی مرتبه اول را آزمون کنید.

۷- مدل زیر را در نظر بگیرید:

$$Y_i = \alpha + \beta X_i + \gamma Z_i + u_i$$

جمله اختلال از فرآیند خودهمبستگی مرتبه دوم پیروی می کنند:

$$u_i = \rho_1 u_{i-1} + \rho_2 u_{i-2} + v_i$$

که v_i فروض کلاسیک را تأمین می‌کند. معادله رگرسیون را تبدیل به معادله‌ای کنید که خودهمبستگی نداشته باشد.

۸- اگر در معادله $Y_i = \alpha + \beta X_i + u_i$ جمله خطا به صورت $u_i = \gamma X_i + \varepsilon_i$ باشد،

الف) کدامیک از فروض کلاسیک نقض شده است؟

ب) تحت چه شرایطی تخمین‌زننده OLS بدون تورش است؟

۹- اگر معادله رگرسیون فاقد عرض از مبدأ باشد، در چه صورتی فرض $E(u_i) = 0$ نقض

می‌شود؟

۱۰- در مسئله ۱ فصل اول، آزمون وایت را برای تشخیص واریانس ناهمسانی انجام دهید.

۱۱- در مسئله ۱ فصل اول، آیا معادله $Y_i = \beta_1 + \beta_2 X_i + \beta_3 Z_i + u_i$ خودهمبستگی مرتبه اول دارد یا نه؟ در صورت وجود خودهمبستگی، آن را رفع کنید.

۱۲- در مسئله ۱ فصل اول، نرخ رشد Y را روی نرخ رشد X و Z برازش کنید. آیا این معادله، خودهمبستگی دارد؟

۱۳- در مسئله ۱ فصل اول، آزمون خودهمبستگی بروش-گادفری را برای معادله $Y_i = \beta_1 + \beta_2 X_i + \beta_3 Z_i + u_i$ انجام دهید.

۱۴- در مسئله ۱ فصل اول، آزمون نرمال بودن باقیمانده‌ها را برای هر یک از معادلات زیر انجام دهید:

$$Y_i = \beta_1 + \beta_2 X_i + u_i \quad \text{الف)}$$

$$Y_i = \beta_1 + \beta_2 Z_i + u_i \quad \text{ب)}$$

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 Z_i + u_i \quad \text{ج)}$$

۱۵- مدل زیر را در نظر بگیرید که خودهمبستگی از فرایند $MA(1)$ تبعیت می‌کند

$$Y_t = \beta Y_{t-1} + u_t$$

$$u_t = \varepsilon_t + \theta \varepsilon_{t-1}$$

ثابت کنید که تخمین β از روش OLS دارای تورش است:

$$\text{plim } \hat{\beta} = \beta + \frac{\theta(1-\beta^T)}{1+\theta^T+2\theta\beta} = \beta + \frac{\theta}{1+\frac{(\theta+\beta)^T}{(1-\beta^T)}}$$

۱۶- استفاده از آماره DW مستلزم وجود عرض از مبدأ و عدم وجود متغیر وابسته تأخیری در سمت راست می‌باشد. اگر این دو شرط نقض شود، مدل زیر را خواهیم داشت:

$$Y_t + \beta Y_{t-1} + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

ثابت کنید که برای آماره DW شرط زیر برقرار است:

$$\text{plim } DW = 2 \left(1 - \frac{\rho\beta(\rho+\beta)}{1+\rho\beta} \right)$$

۱۷- معادله $Y_t = \alpha + \beta X_t + u_t$ دارای واریانس ناهمسانی به شکل $\sigma^2 u_t = \sigma^2 X_t^T$ است. برای رفع واریانس ناهمسانی، چگونه این مدل را برآورد می‌کنید.

۱۹- مدل زیر با $n=30$ مشاهده، برآورد شده است:

$$\hat{Y}_t = 4/75 + 0/88 X_t + 0/44 Y_{t-1} \quad R^2 = 0/95$$

$$(2/4) \quad (4/2) \quad (3/5) \quad DW = 2/21$$

آزمون خودهمبستگی را انجام دهید.

۲۰- اگر مدل $Y_t = \alpha + \beta X_t + u_t$ دارای خودهمبستگی مرتبه دو به صورت $u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \varepsilon_t$ باشد، مدل فوق را تبدیل به مدلی کنید که خودهمبستگی نداشته باشد.

۲۱- در مدل $Y_t = \alpha + \beta X_t + u_t$ اگر خودهمبستگی مرتبه اول وجود داشته باشد، ثابت کنید

که ماتریس واریانس u برابر است با:

$$E(uu') = \sigma^2 \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \dots & \rho^{n-1} \\ \rho^2 & \rho & 1 & \dots & \rho^{n-2} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \rho^{n-1} & \rho^{n-1} & \rho^{n-1} & \dots & \rho^{n-1} \end{bmatrix}$$

u بردار ستونی است که عناصر آن u_t ها هستند.

۲۲- رگرسیون بدون عرض از مبدأ را به صورت $Y_i = \beta X_i + u_i$ در نظر بگیرید. اگر

$$\sigma^2 u_i = \sigma^2 X_i \text{ باشد:}$$

الف) وضعیت واریانس ناهمسانی در این مدل را توضیح را توضیح دهید.

ب) مدل مذکور را با روش OLS برآورد کرده و واریانس آن را حساب کنید.

ج) واریانس ناهمسانی را برطرف کرده و سپس آن را برآورد نمایید.

د) نتایج ب و ج را مقایسه کنید.

ضمیمه فصل ۳: آزمون‌های نقض فروض در Stata

آزمون واریانس ناهمسانی در Stata
 فایل data3
 آزمون‌های واریانس ناهمسانی و بسیاری از آزمون‌های دیگر، با استفاده از باقیمانده‌ها انجام می‌شود. برای محاسبه آن‌ها، بعد از تخمین مدل، فرمان زیر را اجرا می‌کنیم:
 predict e, residuals
 حال می‌توان خطاها را در مقابل زمان و یا هر متغیر دیگری رسم کرده و خصوصیات آن را بررسی نمود.

الف) آزمون وایت

ابتدا معادله مورد نظر را تخمین می‌زنیم:

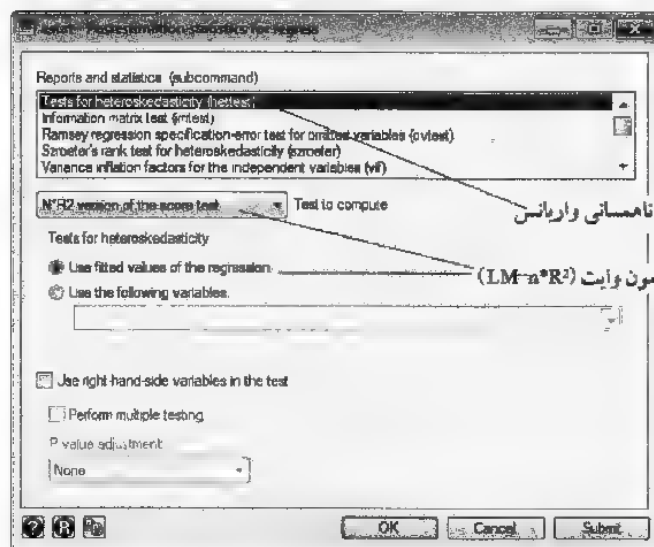
```
. reg i rr d.yno l.i
```

Source	SS	df	MS	Number of obs = 35		
Model	4.1221e+10	3	1.3740e+10	F(3, 31) = 184.73		
Residual	2.3058e+09	31	74380117.7	Prob > F = 0.0000		
Total	4.3527e+10	34	1.2802e+09	R-squared = 0.9470		
				Adj R squared = 0.9419		
				Root MSE = 8624.4		
i	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
rr	-246.8273	200.1467	-1.23	0.227	-655.0293	161.3746
yno						
D1.	1.18792	.1583372	7.50	0.000	.8649894	1.510851
l						
L1.	.8194636	.0523257	15.66	0.000	.7127447	.9261825
_cons	5742.107	5095.64	1.13	0.268	-4650.52	16134.73

حال مسیر زیر را دنبال می‌کنیم:

Specification test, ets. → regression diagnostics → Linear models and related → Statistics

که پنجره زیر باز می شود:



با انتخاب OK نتیجه آزمون وایت عبارت است از:

```
. estat hettest, iid
```

Breusch-Pagan / Cook-Weisberg test for heteroskedasticity

H0: Constant variance

Variables: fitted values of \hat{y}

```
chi2(1)      =      1.47
Prob > chi2   =      0.2248
```

مقدار آماره آزمون (یعنی ۱/۴۷) در ناحیه بحرانی قرار ندارد (زیرا احتمال کمتر از ۰/۰۵ است) و لذا همسانی واریانس رد نمی شود. آزمون وایت را می توان با فرمان زیر نیز انجام داد:

```
estat hettest, iid
```

ب) آزمون بروش - پاکان

آزمون واریانس ناهمسانی بروش - پاکان را با فرمان `hettest` بعد از تخمین معادله مورد نظر به دست آورد.

```
. hettest
```

Breusch-Pagan / Cook-Weisberg test for heteroskedasticity

H0: Constant variance

Variables: fitted values of \hat{y}

```
chi2(1)      =      1.13
Prob > chi2   =      0.2876
```

مقدار آماره آزمون در ناحیه بحرانی قرار ندارد و لذا فرضیه H_0 رد نمی شود یعنی واریانس همان است.

```
gen lne2=log(e^2)
```

۴- رگرسیون $\ln e2$ را روی x و z برآورد می‌کنیم:

```
reg ln2 x z
```

۵- مقادیر به دست آمده از این رگرسیون معادله با برآورد $\hat{\sigma}_e^2$ است، لذا آنها را با فرمان زیر حساب می‌کنیم:

```
predict ln2, xb
```

۶- چون $\ln s^2 = \log(\hat{\sigma}_e^2)$ است، لذا تخمین واریانس را به صورت زیر حساب می‌کنیم:

```
gen wt=exp(ln2)
```

wt معادل با $\hat{\sigma}_e^2$ است.

۷- حال روش GLS را به صورت زیر اعمال می‌کنیم:

```
reg y x, [aweight=1/wt]
```

توجه شود که در روش GLS طرفین معادله را بر جذر wt تقسیم می‌کنیم. در اینجا نیز ما وزن را به صورت معکوس wt تعریف

کرده‌ایم ولی Stata آن را به صورت $\frac{1}{\sqrt{wt}}$ در نظر می‌گیرد.

آزمون خود همبستگی در Stata

آزمون‌های خود همبستگی مبتنی بر استفاده از باقیمانده‌ها هستند. برای محاسبه hae ، بعد از تخمین مدل، فرمان زیر را اجرا می‌کنیم:

```
predict e, residuals
```

حال می‌توان خطاها را در مقابل زمان و یا هر متغیر دیگری رسم کرده و خصوصیات آن را بررسی نمود. برای رسم hae در مقابل زمان از فرمان زیر استفاده می‌کنیم:

```
tsline e
```

از طرف دیگر برای بررسی دقیق‌تر، می‌توان خطاهای زمان t را در مقابل زمان $t-1$ رسم نمود:

```
Twoway (scatter e l.e)
```

همچنین می‌توان ضریب همبستگی e_t و e_{t-1} را نیز حساب نمود که برآوردی از ρ می‌باشد. بدین منظور، فرمان زیر را اجرا می‌کنیم:

```
correlate e l.e
```

آزمون دورین-واتسون

بدین منظور، بعد از تخمین معادله موردنظر، فرمان زیر اجرا می‌کنیم:

```
dwstat
```

با اجرای فرمان فوق، مقدار آماره DW به صورت زیر نشان داده می‌شود:

```
. dwstat
```

```
Durbin-Watson d-statistic( 2, 21) = 1.177749
```

که $DW = 1/178$ است. از رقم داخل پرانتز بزرگتر ۲ پارامتر و ۲۱ مشاهده است.

آزمون نرمال بودن در Stata

آزمون جاک-برا یکی از آزمون‌های نرمال بودن است. مراحل این آزمون عبارت است از:

```
reg y x
```

۱- معادله مورد نظر را تخمین می‌زنیم:

```
predict e, residuals
```

۲- باقیمانده‌ها را حساب می‌کنیم:

```
summarize e, detail
```

۳- شاخص‌های مربوط به e را حساب می‌کنیم:

به جای $summarize$ می‌توان به اختصار از sum استفاده کرد.

۴- شاخص‌های مورد نظر را با فرمان `return list` مشاهده می‌کنیم.

۵- آماره جارک-برا را با فرمان زیر حساب می‌کنیم:

```
scalar jbr=r(N)/6*[r(skewness)^2+0.25*(r(kurtosis)-3)^2]
```

توجه شود که $r(N)$ حجم مشاهدات است و N بایستی با حروف بزرگ نوشته شود.

```
| . scalar jbr=r(N)/6*[r(skewness)^2+0.25*(r(kurtosis)-3)^2]
```

۶- مقدار عددی آماره جارک-برا را با فرمان زیر مشاهده می‌کنیم:

```
di "jarque-bera statistic="jbr
```

```
| . di "jarque-bera statistic="jbr  
jarque-bera statistic=2.6482348
```

۷- اگر $0.99 > jbr$ باشد، نرمال بودن رد می‌شود. در اینجا چون $0.99 > 2.648 = jbr$ است لذا فرضیه نرمال بودن رد نمی‌شود.

متغیرهای مجازی

۵-۱ مقدمه

تاکنون متغیرهای توضیحی را قابل اندازه‌گیری و پیوسته در نظر گرفتیم. اما همواره چنین نیست و موارد بسیاری وجود دارد که برای توضیح یک پدیده نیاز به بررسی عوامل کیفی داریم. معروف‌ترین مثال در این خصوص، بررسی عوامل تعیین‌کننده دستمزد است. بسیاری از این عوامل، کیفی هستند مانند تحصیلات و آموزش، جنسیت، مهارت، نوع صنعت، نژاد و علاوه بر این، موارد دیگری نیز در خصوص تغییرات کیفی وجود دارد که نقش مهمی در تحلیل رگرسیون دارند، مانند: وضع یک مالیات جدید، تغییر تعرفه‌های وارداتی و صادراتی، وضع یک قانون جدید، وقوع یک حادثه، رسیدن یک خبر خوب یا بد به بازار سهام، تغییرات فصلی، تغییرات سیاسی و غیره. اینها و موارد مشابه، موجب توجه به متغیرهای مجازی به‌عنوان شیوه مناسبی برای لحاظ کردن اثر متغیرهای کیفی و تغییرات کیفی شده است. در ادامه به بررسی ماهیت متغیر مجازی و کاربردهای آن می‌پردازیم.

۵-۲ متغیر مجازی^۱

متغیر مجازی یک وضعیت کیفی یا یک تغییر کیفی را توصیف می‌کند که قابل اندازه‌گیری به‌صورت کمی نیست. در ساده‌ترین حالت، می‌توان یک تغییر کیفی را به دو حالت تقسیم نمود:

^۱ dummy variable

۱- تغییر کیفی رخ داده است،

۲- تغییر کیفی رخ نداده است.

و یا یک متغیر کیفی می تواند دو حالت داشته باشد:

۱- حالت موردنظر،

۲- سایر حالت ها.

در چنین مواردی، یک متغیر مجازی برای توصیف این دو حالت تعریف می شود. بر همین اساس متغیر مجازی طوری تعریف می شود که فقط دو مقدار ۰ و ۱ را اختیار می کند: ۱ برای حالت موردنظر و ۰ برای سایر حالت ها.

مثال ۵-۱: فرض کنید عوامل تعیین کننده دستمزد را بررسی می کنیم. به نظر می رسد که جنسیت یکی از این عوامل است. لذا نمونه موردنظر را به دو گروه زن و مرد تقسیم می کنیم. متغیر مجازی D را برای بررسی اثر جنسیت بر دستمزد تعریف می کنیم به گونه ای که $D=0$ برای زنان و $D=1$ برای مردان. لذا دستمزد را تابعی از متغیر مجازی D در نظر می گیریم.

مثال ۵-۲: تصور کنید که در پانزدهم آذر ماه خبری در خصوص شرکت A رسیده است که به نظر می رسد بازدهی آن را تحت تأثیر قرار داده است. برای بررسی تأثیر این خبر، بازدهی های روزانه شرکت A در ۱۰ روز قبل از خبر و ۱۰ روز بعد از خبر را گردآوری کرده ایم. سپس یک متغیر مجازی برای آن تعریف می کنیم که $D=0$ برای روزهای قبل از خبر و $D=1$ برای روزهای بعد از خبر می باشد.

۵-۳ رگرسیون روی متغیر مجازی

فرض کنید Y_i متغیر وابسته است که تحت تأثیر یک عامل کیفی قرار دارد. برای بررسی تأثیر این عامل، متغیر مجازی D_i را تعریف می کنیم. هرگاه این عامل، وجود داشته باشد $D_i=1$ و در غیر این صورت $D_i=0$ می باشد. رگرسیون Y_i روی D_i عبارت است از:

$$Y_i = \alpha + \beta D_i + u_i \quad i = 1, \dots, n \quad (5-1)$$

$$D_i = \begin{cases} 1 & \text{عامل مورد نظر وجود دارد} \\ 0 & \text{عامل مورد نظر وجود ندارد} \end{cases}$$

معادله (۵-۱) را با روش OLS برآورد می‌کنیم که بدین منظور لازم است مجموع مجذور خطاها حداقل شود. از این معادله می‌توان برای تحلیل تأثیر عامل موردنظر استفاده نمود. از آنجا که D_i برابر ۰ و ۱ است، لذا فقط دو مقدار برای Y_i به دست می‌آید.

$$D_i = 0 \Rightarrow Y_i = \alpha \quad \text{عدم وجود عامل موردنظر} \quad (5-2)$$

$$D_i = 1 \Rightarrow Y_i = \alpha + \beta \quad \text{وجود عامل موردنظر}$$

بنابراین تأثیر عامل موردنظر برابر با β است.

$$\frac{\Delta Y_i}{\Delta D_i} = \beta \Rightarrow \Delta Y_i = \beta ; \Delta D_i = 1 - 0 = 1 \quad (5-3)$$

اگر تأثیر عامل موردنظر را بر حسب درصد بیان کنیم، آنگاه درصد افزایش Y عبارت است از:

$$\text{درصد افزایش در } Y = \frac{\Delta Y_i}{Y_i} = \frac{\beta}{\alpha} \quad (5-4)$$

بنابراین، $\frac{\beta}{\alpha}$ بیانگر درصد افزایش در Y است که ناشی از وجود یا وقوع عامل موردنظر می‌باشد.

مثال ۳-۵: تصور کنید می‌خواهیم اثر جنسیت بر دستمزد را بررسی کنیم. بدین منظور متغیر مجازی D_i را تعریف می‌کنیم که $D=0$ برای زنان و $D=1$ برای مردان می‌باشد.

$$Y_i = \alpha + \beta D_i + u_i$$

نتایج این مدل عبارت است از:

$$D_i = 0 \Rightarrow Y_i = \alpha \quad \text{متوسط دستمزد زنان}$$

$$D_i = 1 \Rightarrow Y_i = \alpha + \beta \quad \text{متوسط دستمزد مردان}$$

اگر $\beta > 0$ و معنادار باشد، آنگاه می‌توان گفت که دستمزد مردان به‌طور متوسط بیشتر از دستمزد زنان است. بنابراین، افزایش دستمزد به‌خاطر جنسیت برابر با

$$\frac{\Delta Y_i}{\Delta D_i} = \Delta Y_i = \beta \quad \text{و درصد افزایش دستمزد که ناشی از جنسیت است برابر با}$$

$$\frac{\Delta Y_i}{Y_i} = \frac{\beta}{\alpha} \quad \text{می‌باشد.}$$

۴-۵ دام متغیرهای مجازی^۱

در استفاده از متغیرهای مجازی بایستی دقت شود که اگر جامعه را به دو گروه تقسیم می‌کنیم، فقط برای یک گروه می‌توان متغیر مجازی تعریف نمود. بدین منظور تصور کنید که برای گروه اول D_{1i} و برای گروه دوم D_{2i} را معرفی کنیم. از طرف دیگر می‌دانیم که عرض از مبدأ (α) ضریب متغیری مانند X_i است که تمامی مقادیر آن برابر ۱ می‌باشد.

$$Y_i = \alpha X_i + \beta D_{1i} + \gamma D_{2i} + u_i, \quad X_i = 1 \quad (5-5)$$

متغیرهای مجازی نیز به صورت زیر تعریف شده‌اند:

$$D_{1i} = \begin{cases} 0 & \text{برای گروه ۱} \\ 1 & \text{برای گروه ۲} \end{cases}$$

$$D_{2i} = \begin{cases} 1 & \text{برای گروه ۱} \\ 0 & \text{برای گروه ۲} \end{cases}$$

از آنجا که $D_{1i} + D_{2i} = 1$ است لذا برابر با X_i خواهد بود که موجب همخطی کامل می‌شود و امکان برآورد ضرایب وجود نخواهد داشت. همچنین این موضوع را می‌توان به صورت دیگری بررسی نمود. چون $D_{2i} = 1 - D_{1i}$ است، با جایگذاری در معادله رگرسیون خواهیم داشت:

$$Y_i = \alpha X_i + \beta D_{1i} + \gamma(1 - D_{1i}) + u_i \quad (5-6)$$

$$= \alpha X_i + (\beta - \gamma)D_{1i} + \gamma + u_i$$

γ نیز ضریب متغیری مانند Z_i است که مقادیر آن برابر ۱ است:

$$Y_i = \alpha X_i + (\beta - \gamma)D_{1i} + \gamma Z_i + u_i \quad (5-7)$$

چون $X_i = Z_i = 1$ است، لذا بین X_i و Z_i همخطی کامل برقرار است و در نتیجه، امکان برآورد این معادله وجود ندارد. نتیجه مهم این بحث آن است که وقتی جامعه به دو گروه تقسیم می‌شود، بایستی فقط یک متغیر مجازی تعریف گردد. در حالت کلی، اگر جامعه به m گروه تقسیم شود، بایستی $m-1$ متغیر مجازی معرفی گردد تا مشکل همخطی به وجود نیاید. این موضوع معروف به دام متغیر مجازی است. البته توجه شود که در رگرسیون فاقد عرض از مبدأ، می‌توان m متغیر مجازی تعریف نمود.

^۱ dummy variable trap

۵-۴ رگرسیون روی متغیر مجازی همراه با متغیر توضیحی

فرض کنید که Y_i علاوه بر X_i تابعی از یک عامل کیفی است که آن را با متغیر مجازی D_i نشان می‌دهیم:

$$Y_i = \alpha + \beta X_i + \gamma D_i + u_i \quad (5-8)$$


$$D_i = \begin{cases} 1 & \text{عامل مورد نظر وجود دارد} \\ 0 & \text{عامل مورد نظر وجود ندارد} \end{cases}$$

نتایج حاصل از معادله فوق به صورت زیر تحلیل می‌شود:

$$D_i = 0 \Rightarrow Y_i = \alpha + \beta X_i \quad \text{عامل مورد نظر وجود ندارد}$$

$$D_i = 1 \Rightarrow Y_i = \alpha + \beta X_i + \gamma = (\alpha + \gamma) + \beta X_i \quad \text{عامل مورد نظر وجود دارد}$$

ملاحظه می‌شود که عامل مورد نظر می‌تواند موجب انتقال خط رگرسیون شود. به عبارت دیگر عرض از مبدأ معادله را تغییر می‌دهد. با فرض اینکه $\gamma > 0$ باشد، نمودار زیر را خواهیم داشت:



نمودار ۱-۵ تغییر در عرض از مبدأ

۵-۵ متغیر مجازی و تغییر شیب

عوامل کیفی که اثرشان با متغیرهای مجازی در نظر گرفته می‌شود، علاوه بر عرض از مبدأ، می‌توانند شیب معادله را نیز تغییر دهد. در این صورت اگر فقط شیب و نه عرض از مبدأ را تغییر دهد، می‌توان آن را به صورت زیر توصیف نمود:

$$Y_i = \alpha + \beta X_i + \theta D_i X_i + u_i \quad (5-9)$$


$$D_i = \begin{cases} 1 & \text{عامل موردنظر وجود دارد} \\ 0 & \text{عامل موردنظر وجود ندارد} \end{cases}$$

اثر عامل موردنظر بر شیب را می‌توان به صورت زیر بررسی نمود:

$$D_i = 0 \Rightarrow Y_i = \alpha + \beta X_i + u_i \quad (5-10)$$

$$D_i = 1 \Rightarrow Y_i = \alpha + (\beta + \theta) X_i + u_i$$

بنابراین وقتی عامل یا حادثه موردنظر رخ داده است، شیب معادله رگرسیون را تغییر می‌دهد که برابر با $\beta + \theta$ می‌شود با فرض $\theta > 0$ نمودار زیر را داریم:



نمودار ۲-۵: تغییر شیب

اگر هم شیب و هم عرض از مبدأ تغییر کند می‌توان معادله زیر را در نظر گرفت:

$$Y_i = \alpha + \beta X_i + \gamma D_i + \theta D_i X_i + u_i \quad (5-11)$$

$$D_i = \begin{cases} 1 & \text{برای حالت مورد نظر} \\ 0 & \text{برای سایر حالت‌ها} \end{cases}$$

تحلیل نتایج معادله فوق به صورت زیر است:

$$D_i = 0 \Rightarrow Y_i = \alpha + \beta X_i + u_i \quad \text{عامل یا حادثه موردنظر رخ نداده است}$$

$$D_i = 1 \Rightarrow Y_i = (\alpha + \gamma) + (\beta + \theta) X_i + u_i \quad \text{عامل یا حادثه موردنظر رخ داده است}$$

۵-۶ وجود دو عامل کیفی

فرض کنید که Y_i دستمزد را نشان می‌دهد که متأثر از دو عامل سواد و سابقه کارگران است. برای هر عامل، یک متغیر مجازی تعریف را به صورت زیر معرفی می‌کنیم:

$$Y_i = \alpha + \beta D_{vi} + \gamma D_{ti} + u_i \quad (5-12)$$

$$D_{vi} = \begin{cases} 1 & \text{با سابقه} \\ 0 & \text{کم سابقه} \end{cases}$$

$$D_{ti} = \begin{cases} 1 & \text{با تحصیلات بالا} \\ 0 & \text{با تحصیلات پایین} \end{cases}$$

چهار حالت وجود دارد که عبارتند از:

$$D_{vi} = D_{ti} = 0 \Rightarrow Y_i = \alpha \quad \text{دستمزد کارگر کم سابقه و با تحصیلات پایین}$$

$$D_{vi} = 1, D_{ti} = 0 \Rightarrow Y_i = \alpha + \beta \quad \text{دستمزد کارگر با سابقه و با تحصیلات پایین}$$

$$D_{vi} = 0, D_{ti} = 1 \Rightarrow Y_i = \alpha + \gamma \quad \text{دستمزد کارگر کم سابقه و با تحصیلات بالا}$$

$$D_{vi} = D_{ti} = 1 \Rightarrow Y_i = \alpha + \gamma + \beta \quad \text{دستمزد کارگران با سابقه و با تحصیلات بالا}$$

با تخمین این معادله، اگر β و γ از نظر آماری معنادار باشند، نشان می‌دهد که سابقه و تحصیلات بر دستمزد تأثیر مثبت دارند. α دستمزد پایه را در حالتی نشان می‌دهد که $D_v = D_t = 0$ باشد، یعنی دستمزد فردی کم سابقه و با تحصیلات پایین است. β تأثیر سابقه را نشان می‌دهد که به دو صورت قابل تحلیل است.

۱- تأثیر سابقه برای «فرد با تحصیلات پایین» عبارت است از:

$$\begin{cases} D_{vi} = 0 \Rightarrow Y_i = \alpha \\ D_{vi} = 1 \Rightarrow Y_i = \alpha + \beta \end{cases} \Rightarrow \Delta D_{vi} = 1 \Rightarrow \Delta Y_i = \beta \Rightarrow \frac{\Delta Y_i}{Y_i} = \frac{\beta}{\alpha} \quad (5-13)$$

۲- تأثیر سابقه برای «فرد با تحصیلات بالا» عبارت است از:

$$\begin{cases} D_{vi} = 0 \Rightarrow Y_i = \alpha + \gamma \\ D_{vi} = 1 \Rightarrow Y_i = \alpha + \gamma + \beta \end{cases} \Rightarrow \Delta D_{vi} = 1 \Rightarrow \Delta Y_i = \beta \Rightarrow \frac{\Delta Y_i}{Y_i} = \frac{\beta}{\alpha + \gamma} \quad (5-14)$$

۵-۷ تأثیر متقابل دو عامل کیفی

نکته دیگری که می‌توان به بحث قبلی اضافه نمود آن است که اگر دو عامل کیفی به‌طور همزمان وجود داشته باشند، اثر متقابل آنها را بایستی به‌گونه دیگری تحلیل نمود. به‌عنوان مثال سابقه و تحصیلات ممکن است اثر مضاعفی بر افزایش دستمزد داشته باشند. بدین منظور، مدل زیر را برای لحاظ کردن اثرات متقابل ارائه می‌شود:

$$Y_i = \alpha + \beta D_{vi} + \gamma D_{pi} + \theta D_{vi} D_{pi} + u_i \quad (5-15)$$

حاصل ضرب $D_{vi} D_{pi}$ بیانگر اثر متقابل دو عامل کیفی است؛ سابقه و تحصیلات. در اینجا چهار حالت وجود دارد:

- ۱) $D_{vi} = D_{pi} = 0 \Rightarrow Y_i = \alpha$ متوسط دستمزد کارگر کم سابقه و با تحصیلات پایین
- ۲) $D_{vi} = 1, D_{pi} = 0 \Rightarrow Y_i = \alpha + \beta$ متوسط دستمزد کارگر با سابقه و با تحصیلات پایین
- ۳) $D_{vi} = 0, D_{pi} = 1 \Rightarrow Y_i = \alpha + \gamma$ متوسط دستمزد کارگر کم سابقه و با تحصیلات بالا
- ۴) $D_{vi} = D_{pi} = 1 \Rightarrow Y_i = \alpha + \beta + \gamma + \theta$ متوسط دستمزد کارگر با سابقه و با تحصیلات بالا

θ اثر متقابل سابقه و تحصیلات بر دستمزد را نشان می‌دهد. در حالی که β اثر سابقه و γ اثر تحصیلات را به‌طور جداگانه نشان می‌دهند.

۵-۸ متغیرهای مجازی و تغییر ساختار

فرض کنید که داده‌های گردآوری شده مربوط به دوره ۱۳۸۰-۱۳۴۰ باشد. در طول این دوره وقایع زیادی رخ داده است، مانند وقوع انقلاب اسلامی در سال ۱۳۵۷. ممکن است تصور بر این باشد که وقوع چنین وقایعی می‌تواند رگرسیون را دچار تغییر کند. به‌عنوان مثال آن را منتقل کند و یا شیب آن را تغییر دهد. با استفاده از متغیرهای مجازی می‌توان اثر این وقایع را در نظر گرفت. بدین منظور فرض کنید که معادله رگرسیون به‌صورت $Y_i = \alpha + \beta X_i + u_i$ است و می‌خواهیم اثر واقعه موردنظر را (مثلاً در سال ۱۳۵۷) به این معادله اضافه کنیم.

$$Y_i = \alpha + \beta X_i + \gamma D_i + \theta D_i X_i + u_i \quad (5-16)$$

$$D_i = \begin{cases} 0 & t < 1357 \\ 1 & t \geq 1357 \end{cases}$$

بنابراین، دو معادله رگرسیون داریم، یکی برای قبل از سال ۱۳۵۷ و دیگری برای بعد از آن:

$$D_t = 0 \Rightarrow Y_t = \alpha + \beta X_t + u_t, \quad t < 1357 \quad (5-17)$$

$$D_t = 1 \Rightarrow Y_t = (\alpha + \gamma) + (\beta + \theta) X_t + u_t, \quad t \geq 1357$$

حالت دیگر آن است که اثر واقعه موردنظر را فقط در زمان وقوع آن، لحاظ کنیم. در این صورت معادله زیر را تعریف می‌کنیم:


$$Y_t = \alpha + \beta X_t + \gamma D_t + u_t$$

$$D_t = \begin{cases} 1 & D_t = 1357 \\ 0 & D_t \neq 1357 \end{cases} \quad (5-18)$$

بدین ترتیب اثر وقوع انقلاب در سال ۱۳۵۷ توسط γ نشان داده می‌شود ولی در سالهای قبل و بعد از ۱۳۵۷ توسط معادله $Y_t = \alpha + \beta X_t + u_t$ نشان داده می‌شود. γ اثر واقعه موردنظر است که به صورت تغییر در یک سال معین می‌باشد.

۹-۵ متغیرهای مجازی و مشاهدات دور افتاده^۱

مشاهدات دور افتاده به دلایل مختلفی وجود دارند. یک مشاهده دور افتاده به هر دلیلی که باشد، خارج از محدوده عادی مشاهدات قرار دارد.



^۱outlier


نقطه A یک مشاهده دورافتاده را نشان می‌دهد که فاصله غیرعادی با بقیه مشاهدات دارد. این مشاهده ممکن است بیانگر وقوع یک حادثه بوده که نمی‌توان آن را نادیده گرفت. وجود این مشاهده، خط رگرسیون را از BC به DE تغییر می‌دهد. این موجب افزایش خطا و کاهش R^2 می‌شود. از طرف دیگر ممکن است در نظر گرفتن اثر حادثه‌ای که فقط در نقطه A مشاهده می‌شود، برای ما مهم باشد. در این صورت می‌توان برای نقطه A یک متغیر مجازی تعریف شود:

$$Y_i = \alpha + \beta X_i + \gamma D_i + u_i \quad (5-19)$$

$$D_i = \begin{cases} 1 & \text{برای نقطه } A \\ 0 & \text{در غیر این صورت} \end{cases}$$

بنابراین، γ نشان‌دهنده اثر واقعه‌ای است که نقطه A را به وجود آورده است.

حال اگر مشاهدات دور افتاده به صورت نمودار زیر باشد، می‌توان اثر آن را با معرفی یک متغیر مجازی در نظر گرفت.




نمودار ۵-۴: مشاهدات دور افتاده همسو

$$Y_i = \alpha + \beta X_i + \gamma D_i + u_i \quad (5-20)$$

$$D_i = \begin{cases} 1 & \text{برای نقطه } A \text{ و } B \\ 0 & \text{برای سایر نقاط} \end{cases}$$

در اینجا چون دو نقطه A و B در یک راستا قرار دارند (هر دو بالای مشاهدات اصلی، قرار دارند) معرفی یک متغیر مجازی کفایت می‌کند و اثر هر دو نقطه را در نظر می‌گیرد. اما اگر مشاهدات دور افتاده به صورت زیر باشند، وضعیت متفاوتی خواهد داشت.



نمودار ۵-۵: مشاهدات دور افتاده نهمسو

در این حالت اگر یک متغیر مجازی برای نقاط A و B معرفی کنیم. ضریب آن (γ) بی‌معنی خواهد شد و نمی‌تواند اثر آنها را در نظر بگیرد. زیرا نقطه A اثر مثبت و نقطه B اثر منفی داشته است. به عبارت دیگر، نقطه A رگرسیون را به بالا و نقطه B رگرسیون را به پایین انتقال می‌دهد. بدیهی است که این دو، همدیگر را خنثی می‌کنند و ضریب متغیر مجازی را بی‌معنی خواهد کرد. بنابراین لازم است برای هر یک از این دو نقطه، متغیرهای مجازی جداگانه‌ای را تعریف کنیم. به عبارت دیگر برای تغییرات مثبت (شوکه‌های مثبت) یک متغیر مجازی و برای تغییرات منفی (شوکه‌های منفی) نیز یک متغیر مجازی تعریف نماییم.

$$Y_i = \alpha + \beta X_i + \gamma D_{Vi} + \theta D_{Bi} + u_i \quad (5-21)$$

$$D_{Vi} = \begin{cases} 1 & \text{نقطه A} \\ 0 & \text{سایر نقاط} \end{cases}$$

$$D_{Bi} = \begin{cases} 1 & \text{نقطه B} \\ 0 & \text{سایر نقاط} \end{cases}$$

بدین ترتیب اثر مشاهده نقطه A که ناشی از یک عامل معین بوده توسط γ و اثر مشاهده نقطه B نیز که ناشی از عامل معین دیگری است توسط θ نشان داده می‌شود. به عنوان مثال نقاطی مانند A می‌تواند رسیدن خبرهای خوب به بازار سهام و نقاطی مانند B می‌تواند رسیدن خبرهای بد را نشان دهند. این بحث را می‌توان در موارد زیادی به کار برد. به عنوان مثال تأثیر شوکه‌های مثبت و

منفی که به یک بازار وارد می‌شود یا تأثیر شوک‌های افزایش و کاهش قیمت نفت بر رشد اقتصادی.

۵-۱۰ متغیرهای مجازی و تغییرات فصلی

تغییرات فصلی نیز یکی از عوامل کیفی است که اثر آن به‌ویژه بر تقاضای کالاهای مختلف یا بر تولید کالاهای می‌تواند درخور توجه باشد. فرض کنید که معادله رگرسیون به‌صورت $Y_i = \alpha + \beta X_i + u_i$ است. اثر تغییرات فصلی را با استفاده از متغیرهای مجازی می‌توان وارد این معادله کرد:

$$Y_i = \alpha + \beta X_i + \gamma_1 D_{1i} + \gamma_2 D_{2i} + \gamma_3 D_{3i} + u_i \quad (5-22)$$

$$D_1 = \begin{cases} 1 & \text{فصل تابستان} \\ 0 & \text{سایر فصل‌ها} \end{cases}$$

$$D_2 = \begin{cases} 1 & \text{فصل پاییز} \\ 0 & \text{سایر فصل‌ها} \end{cases}$$

$$D_3 = \begin{cases} 1 & \text{فصل زمستان} \\ 0 & \text{سایر فصل‌ها} \end{cases}$$

توجه شود که در اینجا چهار فصل داریم ولی سه متغیر مجازی تعریف کرده‌ایم. در واقع فصل بهار را به‌عنوان مبنا در نظر گرفته و برای آن متغیر مجازی معرفی نکرده‌ایم. اگر برای فصل بهار نیز متغیر مجازی D_4 را تعریف می‌کردیم، آنگاه حاصل جمع چهار متغیر مجازی در هر شرایطی برابر ۱ می‌شد که با ضریب ثابت α هم‌خطی کامل پیدا می‌کرد و دچار دام متغیر مجازی می‌شدیم. براساس معادله (۵-۲۲) برای هر یک از فصل‌ها، معادله رگرسیون عبارت است از:

$$1) \text{ فصل بهار } D_1 = D_2 = D_3 = 0 \Rightarrow Y_i = \alpha + \beta X_i + u_i$$

$$2) \text{ فصل تابستان } D_1 = 1, D_2 = D_3 = 0 \Rightarrow Y_i = (\alpha + \gamma_1) + \beta X_i + u_i$$

$$3) \text{ فصل پاییز } D_1 = 0, D_2 = 1, D_3 = 0 \Rightarrow Y_i = (\alpha + \gamma_2) + \beta X_i + u_i$$

$$4) \text{ فصل زمستان } D_1 = D_2 = 0, D_3 = 1 \Rightarrow Y_i = (\alpha + \gamma_3) + \beta X_i + u_i$$

نتایج فوق نشان می‌دهد که تفاوت فصل‌ها توسط عرض از مبدأها مشخص شده است که موجب انتقال منحنی به سمت بالا یا پایین می‌شود.

۵-۱۱ توابع لگاریتمی و متغیر مجازی

توابعی که تاکنون معرفی کردیم، خطی بودند. اگر متغیر وابسته به صورت لگاریتمی باشد، آنگاه تحلیل نتایج نیز متفاوت خواهد بود. بدین منظور معادله زیر را در نظر بگیرید:

$$\ln Y_i = \alpha + \beta D_i + u_i \quad (5-23)$$

اگر $D_i = 0$ باشد، $\ln Y_i = \alpha$ و اگر $D_i = 1$ باشد $\ln Y_i = \alpha + \beta$ است. بنابراین تغییر در لگاریتم Y_i برابر با β است:

$$\frac{\Delta \ln Y_i}{\Delta D_i} = \Delta \ln Y_i = \beta \quad (5-24)$$

از طرف دیگر، تغییر Y_i برابر است با:

$$D_i = 0 \rightarrow \ln Y_i = \alpha \Rightarrow Y_i = e^\alpha$$

$$D_i = 1 \rightarrow \ln Y_i = \alpha + \beta \Rightarrow Y_i = e^{\alpha + \beta} = e^\alpha e^\beta$$

$$\Delta Y_i = e^\alpha e^\beta - e^\alpha = e^\alpha (e^\beta - 1)$$

و درصد تغییر در Y برابر است با:

$$\frac{\Delta Y_i}{Y_i} = \frac{e^\alpha (e^\beta - 1)}{e^\alpha} = e^\beta - 1 \quad (5-25)$$

از طرف دیگر می‌دانیم که در حالت پیوسته، $d \ln Y_i = \frac{dY_i}{Y_i}$ است و لذا با مشتق‌گیری از (۵-۲۳) خواهیم داشت:

$$d \ln Y_i = \beta \Rightarrow \frac{dY_i}{Y_i} = \beta \quad (5-26)$$

تفاوت (۵-۲۵) و (۵-۲۶) در این است که در محاسبه (۵-۲۶) فرض کرده‌ایم متغیرها پیوسته و قابل مشتق‌گیری هستند. لذا فرمول (۵-۲۶) به صورت تقریبی است و نه دقیق. به‌هرحال

این دو، تقریباً برابرند و با استفاده از بسط تیلور می‌توان نشان داد که $\beta \equiv 1 - e^\beta$ است.^۱

۵-۱۲ قیمت‌گذاری عوامل کیفی

در برخی از کاربردهای اقتصادی و مالی می‌توان از متغیرهای مجازی به‌عنوان روشی برای قیمت‌گذاری عوامل کیفی استفاده نمود. به‌عنوان مثال در معادله تعیین دستمزد، اثر دستمزد را تابعی از سابقه بدانیم؛ رابطه زیر را برای آن می‌نویسیم:

$$Y_i = \alpha + \beta D_i + u_i \quad (5-27)$$

$$D_i = \begin{cases} 1 & \text{با سابقه} \\ 0 & \text{بدون سابقه} \end{cases}$$

اگر $D_i = 0$ باشد آنگاه دستمزد برابر با $Y_i = \alpha$ است. حال اگر $D_i = 1$ باشد آنگاه دستمزد برابر با $Y_i = \alpha + \beta$ می‌باشد. بنابراین افزایش دستمزد بابت سابقه برابر با β است. β را می‌توان قیمت سابقه دانست. زیرا مقدار دستمزدی است که به‌خاطر داشتن سابقه پرداخت می‌شود. به‌عنوان مثال دیگر، در مدل‌های تقاضا، قیمت تابعی از عوامل و متغیرهای مختلفی است که بعضی از آنها کیفی هستند. در این مدل‌ها، قیمت معادل با تمایل به پرداخت مصرف‌کننده بابت این عوامل است. به‌عنوان مثال مدل زیر را در نظر بگیرید:

$$P_i = \alpha + \beta X_i + \gamma D_i + u_i \quad (5-28)$$

معادله فوق یک معادله تقاضا است که بر حسب قیمت، تنظیم شده است. قیمتی که متقاضی می‌پردازد یا به‌طور کلی، قیمت بازار تابعی از خصوصیات کالا و عوامل تعیین‌کننده آن است. در اینجا فقط دو عامل را ذکر کرده‌ایم که یکی متغیر کمی X_i و دیگری متغیر با عامل کیفی است که D_i آن را نشان می‌دهد. اگر D_i از ۰ به ۱ افزایش یابد، قیمت در هر سطحی از X_i افزایش می‌یابد که مقدار افزایش آن برابر با γ است. لذا γ معادل با قیمت یا ارزش عامل موردنظر از

^۱ بسط تیلور یا تقریب مرتبه اول برای تابع $f(x)$ حول $x = 0$ برابر با $f(x) \equiv f(0) + f'(0)x$ می‌باشد. مشابه این رابطه برای تابع $f(\beta) = e^\beta - 1$ حول $\beta = 0$ برابر است با:

$$f(\beta) \equiv f(0) + f'(0)\beta = (e^0 - 1) + e^0 \beta = \beta$$

دیدگاه مصرف‌کننده است. این نوع از معادلات در رابطه با تقاضای مسکن کاربرد زیادی دارد. طبق این معادله، قیمت مسکن تابعی از عوامل کیفی مانند، دسترسی به بازار، داشتن سیستم گرمایش و سرمایش، موقعیت مکانی، شلوغی و غیره. هر یک از این عوامل نقشی در تعیین قیمت مسکن دارند که ضریب هر یک از آنها، معادل با ارزش (مثبت یا منفی) عامل موردنظر است.

متغیرهای مجازی در Eviews

فرض کنید مدل زیر را می‌خواهیم برآورد کنیم:

$$Y_i = \alpha_0 + \beta_1 X_i + \alpha_1 D_{1i} + \beta_2 D_{1i} X_i + u_i$$

$$D_{1i} = \begin{cases} 1 & X < 100 \\ 0 & X \geq 100 \end{cases}$$

برای تخمین این مدل می‌توان متغیر مجازی D_{1i} را با دستور data D1 تعریف نمود. اما راه ساده‌تر آن است که به‌صورت زیر عمل کنیم.

برای برآورد این معادله، مراحل زیر را انجام می‌دهیم:

- ابتدا متغیر $D2$ را با دستور $\text{genr } D2=1$ ایجاد می‌کنیم.
- معادله مورد نظر را به صورت زیر برآورد می‌کنیم:

$$\text{LS } Y \text{ C } X \text{ D2}*X<100 \text{ (D2}*X<100)*X$$

در واقع ضریب $D2*X<100$ معادل با ضریب D_{1i} (یعنی α_1) و ضریب $(D2*X<100)*X$ معادل با ضریب $D_{1i}X_i$ (یعنی β_2) است.

Equation: UNTITLED Workfile: DATA00: Untitled

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-13.24402	2.000883	-6.618054	0.0006
X	0.194258	0.014948	12.99525	0.0000
D2*X<100	16.57112	2.236107	7.410701	0.0003
(D2*X<100)*X	-0.167156	0.022561	-7.388803	0.0003

R-squared 0.983085 Mean dependent var 8.300000
Adjusted R-squared 0.974828 S.D. dependent var 5.538752
S.E. of regression 0.882252 Akaike info criterion 2.876497
Sum squared resid 4.870214 Schwarz criterion 2.997531
Log likelihood -10.39248 Hannan-Quinn criter 2.743723
F-statistic 116.2387 Durbin-Watson stat 2.381669
Prob(F-statistic) 0.000011

بنابراین معادله تخمینی عبارت است از:

$$\hat{Y}_i = -13.24 + 0.19X_i + 16.57D_{1i} - 0.17D_{1i}X_i$$

مسائل

۱- به نظر می‌رسد که مقدار فروش یک بنگاه در فصول مختلف دارای تفاوت معناداری است. برای فروش این بنگاه یک معادله رگرسیون با استفاده از متغیرهای مجازی به منظور لحاظ کردن اثرات فصلی معرفی کرده و موارد زیر را پاسخ دهید.

الف) آزمون یکسان بودن فروش در فصل‌های مختلف.

ب) آزمون برابری فروش در فصل بهار و پاییز.

ج) آزمون برابری فروش در فصل بهار و پاییز و برابری فروش در تابستان و پاییز.

۲- تقاضای بنزین تابعی از قیمت آن است. لذا دولت می‌خواهد با افزایش قیمت، مصرف بنزین را کاهش دهد. اما استدلال می‌شود که چون قیمت بنزین پایین است، نمی‌توان از سیاست‌های قیمتی برای کنترل مصرف استفاده نمود؛ مگر آنکه قیمت بنزین از یک مقدار آستانه (P^*) عبور کند. این وضعیت را روی نمودار نشان داده و یک معادله تقاضای بنزین را برای آن معرفی کنید.

۳- نظریه مصرف دوزنبیری بیان می‌کند که رفتار مصرفی در واکنش به تغییرات درآمد، قرینه نمی‌باشد. بدین معنی که به افزایش‌های درآمد، واکنش بیشتری نشان می‌دهد ولی به کاهش‌های درآمد، واکنش کمتری نشان می‌دهد. این رفتار مصرفی را با استفاده از متغیرهای مجازی توصیف کنید.

۴- معادله مصرف در مسئله ۳ را چگونه با Eviews برآورد می‌کنید.

۵. مشاهدات مربوط به Y_t در دوره ۸۰-۱۳۵۰ به صورت شش ماهه در دسترس است. داده‌های شش ماهه اول متفاوت از شش ماهه دوم است. با استفاده از متغیرهای مجازی اثر تفاوت فصلی را بر معادله $Y_t = \alpha + \beta X_t + u_t$ مدل‌سازی کنید.

۶- در معادله $Y_t = \alpha F_t + \beta M_t + u_t$ درآمد روی جنسیت برازش شده است. F_t برای زنان و M_t برای مردان برابر با ۱ است. ثابت کنید که $\hat{\alpha}$ برابر با میانگین درآمد زنان و $\hat{\beta}$ برابر با میانگین درآمد مردان است.

۷- معادله $Y_t = \alpha + \beta D_t + u_t$ بیانگر رگرسیون درآمد روی جنسیت می‌باشد. D_t متغیر مجازی است که برای مردان برابر با ۱ و برای زنان برابر با ۰ است. متوسط درآمد زنان و مردان چقدر است.

۸- فرض کنید که داده‌های تقاضا کالای Q و قیمت آن (P) و همچنین درآمد مصرف‌کنندگان (I) به صورت زیر باشد. توجه شود که مقدار تقاضا به صورت فصلی ولی قیمت و درآمد به صورت سالانه در دسترس بوده است.

سال	فصل	Q	P	I
۱۳۸۰		۱۰۰	۵۰	۱۰۰۰
		۱۵۰		
		۱۰۰		
		۱۲۰		
۱۳۸۱		۱۱۰	۶۰	۱۲۰۰
		۱۵۰		
		۱۲۰		
		۱۳۰		
۱۳۸۲		۱۱۵	۶۵	۱۵۰۰
		۱۵۰		
		۱۱۰		
		۱۲۰		
۱۳۸۳		۱۲۰	۸۰	۱۸۰۰
		۱۶۰		
		۱۰۰		
		۱۴۰		
۱۳۸۴		۱۳۰	۹۰	۲۰۰۰
		۱۷۰		
		۱۲۰		
		۱۳۰		

الف) متوسط تقاضا برای هر سال را حساب کرده و معادله تقاضا را بر اساس داده‌های سالانه برآورد کنید.

ب) اثر تفاوت‌های فصلی را در معادله تقاضا آزمون کنید.

۹- معادله $Y_i = \alpha + \beta D_i + u_i$ بیانگر رگرسیون درآمد روی جنسیت است. آزمون برابری درآمد مردان و زنان را چگونه انجام می‌دهید.

۱۰- معادله $Y_i = \alpha F_i + \beta M_i + u_i$ بیانگر رگرسیون درآمد روی جنسیت است (F_i برای زنان و M_i برای مردان). آزمون برابری درآمد مردان و زنان را چگونه انجام می‌دهید.

۱۱- اگر مؤسسه‌ای به کارکنان خود در ساعات معمول، دستمزد ثابتی به ازای هر ساعت پرداخت، ولی بابت اضافه کاری آنها به ازای هر ساعت، دستمزد ثابت و بالاتری پرداخت، یک معادله رگرسیون برای توصیف این وضعیت به کمک متغیرهای مجازی معرفی کنید. همچنین اگر به ازای هر ساعت اضافه کاری، دستمزد بالاتر و متغیر پرداخت، یک معادله رگرسیون برای توصیف این وضعیت به کمک متغیرهای مجازی معرفی کنید.

ضمیمه فصل ۵: متغیرهای مجازی در Stata

متغیرهای مجازی در Stata

استفاده از متغیرهای مجازی مانند متغیرهای معمولی است. اما مسئله مهم این است که متغیر مجازی را برای چه موضوعی می‌سازیم و چه هدفی را دنبال می‌کنیم. بعد از مشخص نمودن موضوع و هدف مورد نظر می‌توان متغیر مجازی را تعریف کرده و سپس مقادیر آن را که برابر با صفر و یک می‌باشند وارد نمود. به عنوان مثال فرض کنید مدل زیر را می‌خواهیم برآورد کنیم:

$$Y_i = \alpha_1 + \beta_1 X_i + \alpha_2 D_{1i} + \beta_2 D_{1i} X_i + u_i$$

$$D_{1i} = \begin{cases} 1 & X < 100 \\ 0 & X \geq 100 \end{cases}$$

ابتدا متغیر مجازی D را با فرمان زیر می‌سازیم:

```
gen d=(x<100)
```

سپس حاصل ضرب متغیرهای D و X را با فرمان زیر حساب می‌کنیم:

```
gen dx=d*x
```

سپس معادله را با فرمان زیر تخمین می‌زنیم:

```
reg x d dx
```

```
. reg y x d dx
```

Source	SS	df	MS	Number of obs = 10		
Model	271.429786	3	90.4765953	F(3, 6) = 116.24		
Residual	4.67021419	6	.778369032	Prob > F = 0.0000		
				R-squared = 0.9831		
				Adj R squared = 0.9746		
Total	276.1	9	30.6777778	Root MSE = .88225		

Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
x	.1942584	.0149484	13.00	0.000	.1576809	.2308358
d	16.57112	2.236107	7.41	0.000	11.09956	22.04268
dx	-.1671556	.0226811	-7.37	0.000	-.2226543	-.1116568
_cons	-13.24402	2.000893	-6.62	0.001	-18.14003	-8.34801

متغیرهای مجازی را به اشکال دلخواه می‌توان ایجاد کرد که برخی از آنها عبارتند از:

```
gen d=(t=1357)
```

```
gen d=(t<=1357)
```

```
gen d=(t>1357)
```

```
gen d=(x>=250)
```

```
gen d=(x=120)
```

فصل ششم

آزمون‌های خاص: تصریح مدل، تغییر ساختاری و علّیت

۶-۱ مقدمه

در تخمین معادلات، مسائل و موضوعات خاصی وجود دارد که متفاوت از مباحث قبلی است. بدین منظور در این فصل به موضوعات خاصی می‌پردازیم که معمولاً در تخمین ضرایب معادلات با آن مواجه می‌شویم. این موضوعات در اغلب موارد، موجب تورش در ضرایب برآوردی و یا بی‌اعتبار شدن آزمون‌های فرضیه می‌شود که لازم است اقداماتی در جهت رفع آنها صورت گیرد. این موضوعات شامل همخطی و مشکلات مربوط به آن، فرم تابعی غلط، حذف متغیرهای مهم، افزودن متغیرهای نامربوط، ثبات ضرایب، خطای اندازه‌گیری و علّیت می‌باشد.

۶-۲ همخطی

۶-۲-۱ مفهوم همخطی

در تخمین پارامترها با استفاده از روش OLS فرض ضمنی این است که متغیرهای توضیحی با یکدیگر همبستگی خطی ندارد. همبستگی خطی بین متغیرها موسوم به همخطی است که در فصل سوم اشاره مختصری به آن شد. همان‌طور که قبلاً دیدیم تخمین ضرایب معادله رگرسیون به صورت $\hat{\beta} = (X'X)^{-1}X'y$ می‌باشد. وضعیت همخطی بستگی به ماهیت ماتریس XX' و یا ماتریس X دارد. در این خصوص، سه حالت وجود دارد:

۱- اگر همخطی کامل وجود داشته باشد بدین معنی است که بین دو یا چند ستون از ماتریس $X'X$ ترکیب خطی وجود دارد (یعنی بین دو یا چند متغیر توضیحی، رابطه خطی وجود دارد) و لذا در ترمینان ماتریس $X'X$ برابر با صفر شده و نمی‌توان ضرایب معادله رگرسیون را برآورد نمود. این حالت بیانگر آن است که لااقل یکی از متغیرهای توضیحی، ترکیب خطی از سایر متغیرهای توضیحی است. به عبارت دیگر در ماتریس X یکی از ستون‌ها ترکیبی از یک یا چند ستون دیگر است. به عنوان مثال اگر $X_{۷}$ ترکیب خطی از سایر متغیرها باشد، بدان معنا است که $X_{۷}$ حاوی هیچ اطلاعات مفید و جدیدی نیست، زیرا اطلاعات آن صرفاً از متغیرهای دیگر به دست آمده است. به عنوان مثال برای برآورد K ضریب، بایستی K ستون (متغیر) مستقل در ماتریس X داشته باشیم. لذا اگر یکی از ستون‌ها (متغیرها) ترکیب خطی از بقیه ستون‌ها باشد، آنگاه یکی از اطلاعات ما، مفید نخواهد بود. باین بدان معنا است که اطلاعات و داده‌ها کمتر از تعداد ضرایب است و لذا امکان برآورد ضرایب وجود نخواهد داشت.

۲- حالت دیگر این است که هیچ‌گونه رابطه خطی بین متغیرها وجود نداشته باشد. در این حالت، کوواریانس یا ضریب همبستگی بین متغیرهای توضیحی صفر می‌شود. همان‌طور که در فصل سوم دیدیم، ماتریس $X'X$ تبدیل به یک ماتریس قطری شده و تخمین هر یک از ضرایب هیچ ارتباطی با سایر ضرایب ندارد.

۳- حالت عمومی و متداول این است که همبستگی بین متغیرهای توضیحی بین صفر و یک می‌باشد. بدیهی است که در این حالت، مشکل هنگامی به وجود می‌آید که همخطی شدید باشد و همبستگی بین متغیرهای توضیحی نسبتاً بزرگ باشد. اگر چه همخطی مشکلاتی را در تخمین پارامترها ایجاد می‌کند، ولی بر خواص تخمین‌زنده‌های OLS تأثیری ندارد.

۲-۲-۶ مشکلات ناشی از همخطی

در فصل سوم دیدیم که در یک رگرسیون دو متغیره اگر بین دو متغیر توضیحی همخطی وجود داشته باشد ضریب همبستگی آنها ($r_{۳۳}$) افزایش می‌یابد و این موجب افزایش واریانس تخمین‌زنده‌های OLS می‌شود. افزایش واریانس نیز به نوبه خود باعث می‌شود که فاصله اطمینان پارامترها، عریض‌تر شود. از طرف دیگر چون واریانس تخمین‌زنده‌ها افزایش می‌یابد، لذا موجب بی‌معنی شدن ضرایب می‌شود و t آنها را غالباً کاهش می‌دهد.

در صورت وجود همخطی، علی‌رغم اینکه مقادیر r کوچک است، ولی R^2 بزرگ می‌باشد. وجود این وضعیت بدان معنا است که یک رابطه خطی بین متغیرهای توضیحی وجود دارد که توانسته است تغییرات متغیر وابسته را به‌خوبی توضیح دهد. توجه شود که مقدار r برای معنادار بودن یک ضریب به‌کار می‌رود، ولی مقدار F برای معنی‌دار بودن همه ضرایب است. ممکن است این دو (یعنی F یا R^2 بزرگ ولی r کوچک) متناقض به‌نظر آید. ولی توجه داریم که در اینجا مسئله مهم رابطه خطی بین متغیرهای توضیحی است. بدین منظور ابتدا کوواریانس بین $\hat{\beta}_1$ و $\hat{\beta}_2$ را در نظر بگیرید که عبارت است از:

$$\text{cov}(\hat{\beta}_1, \hat{\beta}_2) = \frac{-r_{12}\sigma^2}{(1-r_{12}^2)\sqrt{\sum x_{1i}^2 \sum x_{2i}^2}} \quad (6-1)$$

از این فرمول واضح است که با افزایش r_{12} ، کوواریانس تخمین‌زنده‌ها افزایش می‌یابد. بنابراین، در صورت همخطی شدید، کوواریانس تخمین‌زنده‌ها بزرگ می‌شود و لذا حذف یا ورود یک متغیر موجب تغییر در مقدار ضرایب می‌شود. به عبارت دیگر تخمین پارامترها به‌شدت به‌همدیگر وابسته هستند و لذا نمی‌توان مقدار دقیق این پارامترها را برآورد نمود.

۳-۲-۶ شناسایی همخطی

مشکلی که همخطی ایجاد می‌کند آن است که با افزایش ضریب همبستگی بین دو متغیر، واریانس تخمین‌زنده‌های آن‌ها افزایش یابد و مقدار r را کوچک می‌کند در این حالت استنباط ما این است که ضریب مورد نظر بی‌معنی است و باید از مدل حذف شود. این استنباط نادرست بوده و حذف یک متغیر موجب می‌شود تا برآورد ما از سایر ضرایب نیز دچار تورش شود. بدین ترتیب، همخطی هنگامی ایجاد مشکل می‌کند که یک پارامتر به غلط اعتبار خود را از دست بدهد. آزمون‌های تشخیص همخطی نیز باید قادر باشند تا بی‌معنی بودن ضرایب به‌دلیل همبستگی بین متغیرهای توضیحی را تشخیص دهند. از آنجا که تشخیص اینکه یک پارامتر به‌دلیل همخطی، بی‌معنی شده است کار دشواری است، لذا نمی‌توان به یک آزمون قطعی برای تشخیص همخطی دست یافت. ولی برخی قواعد و روش‌های توافقی وجود دارند که برای تشخیص همخطی مورد استفاده قرار می‌گیرند.

یکی از معیارهای ساده جهت شناسایی همخطی استفاده از ضرایب همبستگی بین متغیرهای توضیحی است. اگر ضرایب همبستگی بین متغیرهای توضیحی، نسبتاً بزرگ باشد بیانگر همخطی نسبتاً شدید است. اما اگر ضرایب همبستگی کوچک باشند بدین معنی نیست که همخطی وجود ندارد. به عبارت دیگر علیرغم پایین بودن این ضرایب، ممکن است همخطی نسبتاً بالایی در مدل وجود داشته باشد. در چنین شرایطی، یک پیشنهاد این است که از ضرایب همبستگی جزئی استفاده شود که در فصل دوم راجع به آنها بحث شد. معمولاً گفته می‌شود که اگر برای یک معادله رگرسیون، ضریب همبستگی ساده بین متغیرهای توضیحی بیش از $\sqrt{R^2}$ باشد، همخطی شدید است.

فایل data2

محاسبه ضرایب همبستگی ساده در Eviews

نحوه محاسبه ضرایب همبستگی ساده با استفاده از نرم‌افزار Eviews در فصل دوم توضیح داده شد. به عنوان مثال در برآورد تابع تولید، متغیرهای تولید ناخالص داخلی (Y)، نیروی کار (L) و سرمایه (K) را داریم که ضرایب همبستگی آنها عبارت است از:

	Y	K	L
Y	1	0.894944	0.917590
K	0.894944	1	0.867922
L	0.917590	0.867922	1

جدول فوق نشان می‌دهد که ضریب همبستگی بین L و K حدود ۰/۸۹۸ می‌باشد که نسبتاً بالا است و نشان از همخطی است. از طرف دیگر اگر به جای تابع تولید، از معادله نرخ رشد استفاده کنیم، در این صورت معمولاً همخطی بین متغیرهای توضیحی کاهش می‌یابد. ضرایب همبستگی بین نرخ رشد متغیرها عبارتند از:

	GY	GK	GL
GY	1	0.4301294	0.555101
GK	0.4301294	1	0.243341
GL	0.5551013	0.2433416	1

جدول فوق نشان می‌دهد که ضریب همبستگی بین نرخ رشد کار و سرمایه حدود ۰/۲۴۳ می‌باشد که نشان می‌دهد در چنین حالتی همخطی قابل اغماض است.

روش دیگر برای شناسایی همخطی این است که هر یک از متغیرهای توضیحی را روی بقیه متغیرهای توضیحی برازش نموده و ضریب تعیین آن را حساب کرده و با ضریب تعیین مدل اصلی مقایسه کنیم. اگر ضریب تعیین معادله مورد نظر از ضریب تعیین مدل اصلی بیشتر شد، در این

صورت همخطی شدید و غیر قابل اغماض است. به عنوان مثال فرض کنید که مدل زیر را داشته باشیم:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_K X_{Ki} + u_i = \beta_1 + \sum_{i=2}^K \beta_i X_{ii} + u_i \quad (6-2)$$

با تخمین این مدل، R^2 نیز به دست می آید. از طرف دیگر، به عنوان مثال برای X_1 داریم:

$$X_{it} = \gamma_1 + \gamma_2 X_{2i} + \gamma_3 X_{3i} + \dots + \gamma_K X_{Ki} + \varepsilon_i = \gamma_1 + \sum_{j=2}^K \gamma_j X_{ji} + \varepsilon_i \quad (6-3)$$

ضریب تعیین این معادله را با R_i^2 نشان داده و با ضریب تعیین مدل اصلی (R^2) مقایسه می کنیم. اگر $R_i^2 > R^2$ باشد در این صورت همخطی شدید است. اما این روش به سختی می تواند در تشخیص همخطی کمک کند، زیرا تصور کنید که $R^2 = 0.94$ و $R_i^2 = 0.97$ باشد در این صورت رابطه خطی شدیدی بین X_i و سایر X ها وجود دارد، هر چند که R_i^2 اندکی از R^2 کوچکتر است. بنابراین روش مناسب تر آن است که معنادار بودن R_i^2 را آزمون کنیم. بدین صورت که اگر R_i^2 معنی دار باشد بیانگر وجود همخطی شدید بین X_i با سایر X ها است. برای آزمون معنی دار بودن R_i^2 ، از تابع F استفاده می کنیم:

$$F_i = \frac{ESS/(n-(K-1))}{RSS/((K-1)-1)} = \frac{n-K+1}{K-2} \frac{R_i^2}{1-R_i^2} \quad (6-4)$$

درجه آزادی F_i به ترتیب $K-2$ و $n-K+1$ می باشد که n تعداد مشاهدات و K تعداد پارامترهای تخمینی در معادله رگرسیون X_i روی X ها می باشد. اگر مقدار F_i از F جدول بزرگتر باشد در این صورت R_i^2 به اندازه کافی بزرگ است و حاکی از همخطی شدید X_i با سایر X ها می باشد.

روش فوق هر چند مفید و ساده است اما ممکن است در شناسایی برخی از انواع همخطی نتواند کمک نماید. به عنوان مثال فرض کنید که ترکیب خطی از X_2 و X_3 دارای همخطی شدیدی با ترکیب خطی از سایر متغیرها باشد. در این صورت بایستی ترکیب خطی از X_2 و X_3 را روی سایر متغیرهای توضیحی برازش کنیم. در چنین شرایطی نمی توان از روش فوق استفاده نمود. روش دیگر در شناسایی همخطی، بررسی دترمینان ماتریس $X'X$ است. هر چه دترمینان $X'X$ نزدیک به صفر باشد بیانگر همخطی شدید بین X_i ها است، اما مشکل این روش این است که

دترمینان $X'X$ چقدر باید به صفر نزدیک باشد تا بتوان گفت که بین X_1 ها همخطی شدید وجود دارد.

۶-۲-۴ راه‌های کاهش همخطی

مشکل همخطی، مربوط به نمونه است. به عنوان مثال تصور کنید که مصرف را تابعی از درآمد و ثروت می‌دانیم. از قبل مشخص است که بین درآمد و ثروت یک رابطه مستقیم وجود دارد. یعنی افراد ثروتمندتر دارای درآمد بالاتر می‌باشند. اما نمی‌توان به این قضاوت اکتفا نمود، بلکه بایستی ببینیم که در نمونه یا بر اساس داده‌های جمع‌آوری شده آیا همخطی شدیدی بین درآمد و ثروت وجود دارد یا نه. لذا در بررسی همخطی، بایستی راجع به داده‌ها بحث نمود و نه در مورد مدل یا روش تخمین.

بر اساس بحث فوق یکی از راه‌های کاهش همخطی این است که حجم نمونه را افزایش دهیم. با افزایش حجم نمونه ممکن است همخطی کاهش یابد. به عنوان مثال در معادله‌ای که شامل دو متغیر X_1 و X_2 است، اگر با افزایش حجم نمونه ضریب همبستگی X_1 و X_2 تغییر نکند، در این صورت واریانس تخمین‌زننده‌ها کاهش می‌یابد. زیرا به عنوان مثال واریانس $\hat{\beta}_1$ برابر است با:

$$\text{var}(\hat{\beta}_1) = \frac{\sigma^2}{(1-r_{12}^2) \sum X_{2i}^2} \quad (6-5)$$

با افزایش حجم نمونه، $\sum X_{2i}^2$ افزایش می‌یابد و لذا واریانس $\hat{\beta}_1$ را کاهش می‌دهد. با کاهش واریانس $\hat{\beta}_1$ ، امکان برآورد دقیق‌تری از این پارامتر فراهم می‌شود.

روش دیگر برای کاهش همخطی، حذف متغیری است که موجب همخطی می‌شود. اما مشکل این روش آن است که مدلی را که از نظر تئوری درست است تبدیل به مدلی می‌کنیم که از تئوری فاصله می‌گیرد. در چنین شرایطی دچار مشکل «تورش تصریح» می‌شویم که موجب تورش ضرایب تخمینی می‌شود. (به فصل ۲ و ۳ مراجعه شود).

راه دیگر برای کاهش همخطی، استفاده از ترکیب داده‌های سری زمانی و مقطعی است. به عنوان مثال فرض کنید می‌خواهیم تابع تقاضای یک کالا را برآورد کنیم و متغیرهای توضیحی ما شامل قیمت و درآمد می‌باشد. در اینجا می‌توان ضریب مربوط به متغیر درآمد را با استفاده از داده‌های مقطعی (گروه‌های درآمدی) برآورد نمود.

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t \quad (9-6)$$

Y_t مصرف کالای مورد نظر، X_2 و X_3 به ترتیب درآمد و قیمت می باشند. در این حالت ابتدا معادله $Y_t = \alpha_1 + \alpha_2 X_{2t}$ را با داده های مقطعی برآورد کرده و سپس α_1 را به عنوان تخمین β_1 در نظر می گیریم. توجه شود که در اینجا فرض بر این است که $\hat{\alpha}_2 = \hat{\beta}_2$ خواهد بود. سپس بر اساس $\hat{\beta}_2$ ، معادله رگرسیون را به صورت زیر می نویسیم:

$$\begin{aligned} Y_t &= \beta_1 + \hat{\beta}_2 X_{2t} + \beta_3 X_{3t} + u_t \\ Y_t - \hat{\beta}_2 X_{2t} &= \beta_1 + \beta_3 X_{3t} + u_t \\ Y_t^* &= \beta_1 + \beta_3 X_{3t} + u_t, \quad Y_t^* = Y_t - \hat{\beta}_2 X_{2t} \end{aligned} \quad (9-7)$$

حال می توان معادله آخر را برآورد نمود و ضرایب $\hat{\beta}_1$ و $\hat{\beta}_3$ را نیز به دست آورد. یکی دیگر از روش هایی که می تواند به کاهش همخطی کمک نماید استفاده از تئوری است. به عنوان مثال تابع تولید را به صورت زیر در نظر بگیرند:

$$\ln Y_t = \alpha + \beta_1 \ln L_t + \beta_2 \ln K_t + u_t \quad (9-8)$$

فرض کنید از قبل می دانیم که \hat{Y}_t^2 است. در این صورت تابع تولید را با توجه به $\beta_1 = 1 - \beta_2$ صورت زیر می نویسیم:

$$\begin{aligned} \ln Y_t &= \alpha + (1 - \beta_2) \ln L_t + \beta_2 \ln K_t + u_t \\ \ln Y_t - \ln L_t &= \alpha + \beta_2 (\ln K_t - \ln L_t) + u_t \\ \ln \left(\frac{Y_t}{L_t} \right) &= \alpha + \beta_2 \ln \left(\frac{K_t}{L_t} \right) + u_t \end{aligned} \quad (9-9)$$

در چنین شرایطی اگر L و K همخطی شدید داشته باشند، با اعمال قید $\beta_1 + \beta_2 = 1$ تعداد متغیرهای توضیحی را تقلیل می دهیم. در واقع این راهی برای اعمال و آزمون قید $\beta_1 + \beta_2 = 1$ است، هر چند که به برطرف کردن همخطی نیز کمک می کند.

یکی دیگر از روش های کاهش همخطی، تبدیل متغیرها است. به عنوان مثال در برآورد تابع تولید، اگر به جای مقدار متغیرها از تفاضل آنها یا نرخ رشد آنها استفاده کنیم، معمولاً همخطی کاهش می یابد. تابع تولید کاب-داگلاس را در نظر بگیرید که لگاریتم آن به صورت زیر است:

$$\ln Y_t = \alpha + \beta_1 \ln L_t + \beta_2 \ln K_t + u_t$$

با دیفرانسیل گیری از تابع تولید، مدل زیر به دست می آید:

$$\dot{Y}_t = \beta_L \dot{L}_t + \beta_K \dot{K}_t + \varepsilon_t \quad (6-10)$$

\dot{X}_t بیانگر نرخ رشد متغیر X_t می‌باشد. در اینجا همخطی بین \dot{L} و \dot{K} عملاً ناچیز است. اما مشکل این است که ε_t بیانگر تغییرات u_t است که به صورت $\varepsilon_t = \frac{du_t}{u_t} \approx \frac{u_t - u_{t-1}}{u_{t-1}}$ می‌باشد. در چنین شرایطی معمولاً ε_t دچار خودهمبستگی می‌شود که باید برای آن نیز چاره‌ای اندیشید.

۶-۳ فرم تابعی نادرست

یکی از فروض معادلات رگرسیون کلاسیک این است که فرم تابعی به درستی انتخاب شده است. اما ممکن است این فرض درست نباشد. برای آزمون خطی بودن مدل، رمزی (۱۹۶۹) آزمونی را ارائه نموده است که براساس آن می‌توان نادرست بودن شکل تابع را تشخیص داد. این آزمون معروف به آزمون RESET رمزی است. این آزمون از یک رگرسیون کمکی استفاده می‌کند. در این رگرسیون مقادیر باقیمانده (\hat{u}_t) بر روی توان‌های مختلف \hat{Y}_t برازش می‌شود.

$$\hat{u}_t = \alpha_1 + \alpha_2 \hat{Y}_t^2 + \alpha_3 \hat{Y}_t^3 + \dots + \alpha_p \hat{Y}_t^p + v_t \quad (6-11)$$

وقتی که \hat{Y}_t با توان‌های مختلف در نظر گرفته می‌شود بدان معنا است که انواع روابط غیرخطی را در نظر گرفته‌ایم. به عنوان مثال \hat{Y}_t^2 عبارت است از:

$$\hat{Y}_t^2 = (\hat{\beta}_1 + \hat{\beta}_2 X_{1t} + \dots + \hat{\beta}_K X_{Kt})^2 \quad (6-12)$$

در اینجا وقتی پیرانتز را به توان برسانیم، هم توان‌های دوم متغیرها و هم حاصل ضرب‌های آنها در نظر گرفته شده است.

برای آزمون درستی شکل معادله، از R^2 استفاده می‌کنیم. بدین منظور مقدار R^2 را برای مدل (۶-۱۱) به دست می‌آوریم. همان‌طور که قبلاً اشاره شد، nR^2 (برای معادله ۶-۱۱) دارای توزیع مجانبی χ^2 با درجه آزادی $p-1$ می‌باشد (p تعداد پارامترهای تخمینی است)^۱. اگر مقدار nR^2 از

^۱ در فصل هفتم ثابت می‌شود که nR^2 برابر با آماره ضریب لاگرانژ (LM) است.

مقدار χ^2 جدول $(\chi^2_{1-\alpha, p-1})$ بزرگتر باشد، فرضیه صفر مبنی بر اینکه «فرم تابعی درست است» رد می‌شود.

آزمون RESET رمزی را با کمک تابع F نیز می‌توان انجام داد. بدین منظور فرض کنید که مدل مورد نظر به صورت (۶-۱۳) باشد:

$$Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \dots + \beta_K X_{Kt} + u_t \quad (6-13)$$

با تخمین این مدل، مقدار R^2 را محاسبه کرده و آن را با R^2_{old} نشان می‌دهیم. حال معادله (۶-۱۳) را در حالی که $\hat{Y}_t^2, \hat{Y}_t^3, \dots$ را به آن اضافه شده است، برآورد می‌کنیم:

$$Y_t = \beta_1 + \beta_2 X_{1t} + \dots + \beta_K X_{Kt} + \gamma_1 \hat{Y}_t^2 + \gamma_2 \hat{Y}_t^3 + \dots + \gamma_p \hat{Y}_t^{p+1} + v_t \quad (6-14)$$

با برآورد این مدل، مقدار R^2 نیز به دست می‌آید که آن را R^2_{new} می‌نامیم. برای آزمون معنی‌دار بودن متغیرهای $\hat{Y}_t^2, \hat{Y}_t^3, \dots$ باید دید که آیا وارد نمودن آنها تفاوت محسوسی در قدرت توضیحی مدل ایجاد کرده است یا نه. بدیهی است که اگر R^2_{new} به اندازه کافی از R^2_{old} بزرگتر باشد می‌توان گفت که فرم تابعی (۶-۱۳) نادرست است و باید فرم دیگری را در نظر گرفت.

بدین منظور از تابع F استفاده می‌کنیم:

$$F_{p, n-K-p} = \frac{(R^2_{new} - R^2_{old})/p}{(1 - R^2_{new})/(n - K - p)} \quad (6-15)$$

$$= \frac{n - K - p}{p} \frac{R^2_{new} - R^2_{old}}{1 - R^2_{new}}$$

اگر مقدار F از F جدول $(F_{1-\alpha, p, n-K-p})$ بیشتر باشد، نشان می‌دهد که فرم تابعی (۶-۱۳) نادرست است و باید فرم تابعی دیگری را در نظر بگیریم. این فرم جدید ممکن است همراه با توانهای بالاتر برای X ها یا به صورت حاصل ضرب X ها باشد. همچنین ممکن است به صورت لگاریتمی و یا هر فرم غیرخطی دیگری باشد.

آزمون RESET رمزی در Eviews

فایل data2

با برآورد رابطه بین نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) و نرخ رشد نیروی کار (GL) و نرخ رشد موجود سرمایه (GK)، نتایج زیر به دست آمده است:

Equation: UNTITLED Workfile: YNO::Untitled				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: GYNO				
Method: Least Squares				
Date: 01/29/11 Time: 01:10				
Sample (adjusted): 1348 1380				
Included observations: 35 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GL	1.107676	0.174091	6.362644	0.0000
GK	0.418728	0.072549	5.771668	0.0000
R-squared	0.691456	Mean dependent var	5.677239	
Adjusted R-squared	0.682106	S.D. dependent var	7.492675	
S.E. of regression	4.224528	Akaike info criterion	5.775138	
Sum squared resid	588.9391	Schwarz criterion	5.864015	
Log likelihood	-99.06491	Hannan-Quinn criter.	5.805818	
Durbin-Watson stat	1.578005			

در پنجره فوق، برای انجام آزمون RESET بصورت زیر عمل می‌کنیم:

View → Stability Tests → Ramsey RESET Test

در اینجا پنجره‌ای باز می‌شود که در مقابل گزینه Number of Fitted Terms عددی را باید وارد کنیم که بیانگر مقدار p یعنی توان چند جمله‌ای در معادله (1-11) می‌باشد. اگر عدد ۱ را وارد کنیم بدان معنا است که فقط \hat{Y}_1^2 را در نظر گرفته‌ایم.

RESET Specification

Number of fitted terms:

OK Cancel

با انتخاب OK، نتایج بصورت زیر نشان داده می‌شود:

Equation: UNTITLED Worksheet: (NO) Untitled				
View	Proc	Object	Print	Name Freeze Estimate Forecast Stats Resids
Ramsey RESET Test				
Equation: UNTITLED				
Specification: GYNO GL GK				
Omitted Variables: Squares of fitted values				
	Value	df	Probability	
t-statistic	1.902919	32	0.0661	
F-statistic	3.821101	(1, 32)	0.0661	
Likelihood ratio	3.752080	1	0.0527	
F-test summary:				
	Sum of Sq	df	Mean Squares	
Test SSR	59.86923	1	59.86923	
Restricted SSR	588.9391	33	17.84664	
Unrestricted SSR	529.0898	32	16.53343	
Unrestricted SSR	529.0699	32	16.53343	
LR test summary:				
	Value	df		
Restricted LogL	-98.06491	33		
Unrestricted LogL	-87.18887	32		
Unrestricted Test Equation:				
Dependent Variable: GYNO				
Method: Least Squares				
Date 01/29/11 Time 01:12				
Sample: 1346 1380				
Included observations: 35				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GL	0.871087	0.208657	4.174635	0.0002
GK	0.379099	0.072868	5.202536	0.0000
FITTED^2	0.016770	0.008813	1.902919	0.0661
R-squared	0.722821	Mean dependent var	5.677239	
Adjusted R-squared	0.705497	SD dependent var	7.492675	
SE of regression	4.086133	Akaike info criterion	5.725078	
Sum squared resid	529.0698	Schwarz criterion	5.858394	
Log likelihood	-97.18887	Hannan-Quinn criter.	5.771099	
Durbin-Watson stat	1.497463			

در پنجره فوق، مقدار t مربوط به ضریب \hat{Y}_t^2 (که در اینجا با FITTED^2 نشان داده می‌شود) است که در قسمت پایین نیز ارائه شده است. اما مقدار F و احتمال مربوطه نشان می‌دهد که فرم تابعی درست نمی‌باشد و نیاز به در نظر گرفتن فرم دیگری داریم. لازم به ذکر است که مقدار F از RSS های مقید و غیر مقید به دست آمده است که در قسمت F-Test Summary ارائه شده‌اند. همچنین، بعد از F مقدار نسبت درستنمایی نیز محاسبه شده که برابر با $3/75$ می‌باشد و با توجه به احتمال مربوطه، نشان می‌دهد که فرم تابعی، غلط می‌باشد. نسبت درستنمایی (LR) به صورت زیر به دست می‌آید که اجزای آن در قسمت LR test summary ارائه شده است:

$$LR = -2[\log(L_R) - \log(L_{UR})] = -2[(-99/06491) - (-97/18887)] = 3/752080$$

که L_R تابع درستنمایی مقید و L_{UR} تابع درستنمایی غیر مقید می‌باشد.

از طرف دیگر اگر FITTED^2 را که برابر با $(\hat{\beta}_{GL} + \hat{\beta}_{GK})^2$ است به توان ۲ برسانیم، متغیرهای توضیحی هم با توان ۲ و هم به صورت حاصل ضرب وارد معادله اصلی می‌شوند. با وارد نمودن این متغیرها، تخمین مدل عبارت است از:

Equation: UNTITLED Workfile: VNO: Untitled				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Dependent Variable: GYNO				
Method: Least Squares				
Date: 01/29/11 Time: 02:07				
Sample (adjusted): 1346 1380				
Included observations: 35 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GL	1.104422	0.398952	2.782258	0.0092
GK	0.282346	0.131255	2.151117	0.0398
GL^2	0.000903	0.040894	0.022197	0.9824
GK^2	0.011805	0.008633	1.344246	0.1889
GL*GK	0.002031	0.016039	0.112580	0.9111
R-squared	0.732655	Mean dependent var	5.677239	
Adjusted R-squared	0.697009	S.D. dependent var	7.492875	
S.E. of regression	4.124314	Akaike info criterion	5.803240	
Sum squared resid	510.2890	Schwarz criterion	6.025433	
Log likelihood	-85.55870	Hannan-Quinn criter.	5.879841	
Durbin-Watson stat	1.668578			

جدول فوق نشان می‌دهد که ضرایب GL^2 و $GL*GK$ کاملاً بی‌معنی هستند، لذا این دو را از معادله حذف کرده و فقط GK^2 را نگه می‌داریم. در این حالت نتایج زیر به دست می‌آید:

Equation: UNTITLED Workfile: VNO: Untitled				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Dependent Variable: GYNO				
Method: Least Squares				
Date: 01/29/11 Time: 02:09				
Sample (adjusted): 1346 1380				
Included observations: 35 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GL	1.121350	0.164716	6.807802	0.0000
GK	0.277610	0.093577	2.968646	0.0057
GK^2	0.012176	0.005492	2.217030	0.0338
R-squared	0.732538	Mean dependent var	5.677239	
Adjusted R-squared	0.715822	S.D. dependent var	7.492875	
S.E. of regression	3.994224	Akaike info criterion	5.689392	
Sum squared resid	510.6226	Schwarz criterion	5.022708	
Log likelihood	-96.58437	Hannan-Quinn criter.	5.735413	
Durbin-Watson stat	1.684315			

ملاحظه می‌شود که علاوه بر ضرایب GL و GK ، ضریب GK^2 نیز معنی‌دار است. همچنین نسبت به مدل اصلی که فقط شامل متغیرهای توضیحی GL و GK است، دارای \bar{R}^2 بالاتری است.

۶-۴ حذف متغیرهای مهم

فرض کنید مدل صحیح به صورت زیر باشد:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t \quad (9-16)$$

حال تصور کنید که متغیر مهمی مانند X_{2t} را حذف کرده و مدل زیر را برآورد نماییم:

$$Y_t = \alpha_1 + \alpha_2 X_{2t} + u_t \quad (6-17)$$

پیامد حذف متغیر مهم X_{3t} آن است که اولاً β_2 را صفر فرض کرده‌ایم و ثانیاً در برآورد ضریب X_{2t} دچار تورش می‌شویم، زیرا $E(\hat{\alpha}_2) \neq \beta_2$ است. تخمین ضریب X_{2t} از معادله (6-17) عبارت است از:

$$\hat{\alpha}_2 = \frac{\sum x_{2t} y_t}{\sum x_{2t}^2}$$

از معادله (6-16) به جای Y_t قرار داده و $\hat{\alpha}_2$ را به صورت زیر می‌نویسیم:

$$\begin{aligned} \hat{\alpha}_2 &= \frac{\sum x_{2t} y_t}{\sum x_{2t}^2} = \frac{\sum x_{2t} Y_t}{\sum x_{2t}^2} = \frac{\sum x_{2t} (\beta_1 + \beta_2 X_{1t} + \beta_3 X_{3t} + u_t)}{\sum x_{2t}^2} \\ &= \beta_2 + \beta_3 b_{32} + \frac{\sum x_{2t} u_t}{\sum x_{2t}^2} \end{aligned}$$

زیرا $\sum x_{2t} = 0$ و $\sum x_{2t} X_{1t} = \sum x_{2t}^2$ است. همچنین b_{32} از رگرسیون $X_{3t} = b_1 + b_{23} X_{2t} + \varepsilon_t$ به دست می‌آید که برابر است با:

$$b_{32} = \frac{\sum x_{2t} x_{3t}}{\sum x_{2t}^2}$$

امید ریاضی $\hat{\alpha}_2$ برابر است با:

$$E(\hat{\alpha}_2) = \beta_2 + \beta_3 b_{32} + E\left(\frac{\sum x_{2t} u_t}{\sum x_{2t}^2}\right)$$

چون امید ریاضی u_t برابر با صفر است لذا خواهیم داشت:

$$E(\hat{\alpha}_2) = \beta_2 + \beta_3 b_{32} \quad (6-18)$$

بنابراین مقدار تورش $\hat{\alpha}_2$ بستگی به β_2 و b_{32} دارد. اگر β_2 برابر با صفر باشد مقدار تورش نیز صفر خواهد شد. اما چنین نخواهد بود زیرا X_{3t} یک متغیر مهم است و لذا ضریب آن از نظر آماری معنادار است. حالت دیگری که تورش $\hat{\alpha}_2$ را صفر می‌کند، این است که b_{32} صفر باشد. اگر b_{32} صفر باشد بدین معنا است که متغیرهای توضیحی X_{2t} و X_{3t} هیچ رابطه‌ای ندارند و لذا برآورد ضریب X_{2t} متأثر از X_{3t} نخواهد بود.

در حالت کلی فرض کنید که شکل ماتریسی مدل صحیح به صورت زیر باشد:

$$y = X\beta + u \quad (6-19)$$

اما زیر برآورد می‌شود که $K-p$ متغیر از آن حذف شده است:

$$y = X_p \beta_p + v \quad (9-20)$$

ماتریس X_p شامل متغیرهای X_{1i} تا X_{pi} می‌باشد، در حالی که X شامل متغیرهای X_{1i} تا X_{Ki} است که $K > p$ می‌باشد. بدین ترتیب متغیرهای X_{p+1} تا X_K از مدل حذف شده‌اند. با برآورد مدل (9-20)، تخمین β_p عبارت است از:

$$\hat{\beta}_p = (X_p' X_p)^{-1} (X_p' y)$$

حال به جای y از (9-19) د (9-21) قرار می‌دهیم:

$$\begin{aligned} \hat{\beta}_p &= (X_p' X_p)^{-1} X_p' (X \beta + u) \\ &= (X_p' X_p)^{-1} X_p' X \beta + (X_p' X_p)^{-1} X_p' u \end{aligned} \quad (9-22)$$

اما می‌توان ماتریس X را به صورت زیر نوشت:

$$X = \begin{bmatrix} X_{11} & X_{11} & \cdots & X_{p1} & X_{p+1,1} & X_{p+1,1} & \cdots & X_{K1} \\ X_{11} & X_{11} & \cdots & X_{p1} & X_{p+1,1} & X_{p+1,1} & \cdots & X_{K1} \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ X_{1n} & X_{1n} & \cdots & X_{pn} & X_{p+1,n} & X_{p+1,n} & \cdots & X_{Kn} \end{bmatrix} = [X_p \quad X_E]$$

X_E ماتریسی است که شامل داده‌های مربوط به X_{p+1} تا X_K می‌باشد.

همچنین می‌توان β را به صورت $\beta = \begin{bmatrix} \beta_p \\ \beta_E \end{bmatrix}$ نوشت که β_p برداری با ابعاد $p \times 1$ و β_E

برداری با ابعاد $(K-p) \times 1$ می‌باشد. با جایگذاری به جای X و β در (9-22) می‌توان $\hat{\beta}_p$ را به صورت زیر نوشت:

$$\begin{aligned} \hat{\beta}_p &= (X_p' X_p)^{-1} X_p' [X_p \quad X_E] \begin{bmatrix} \beta_p \\ \beta_E \end{bmatrix} + (X_p' X_p)^{-1} X_p' u \\ &= (X_p' X_p)^{-1} (X_p' X_p \beta_p + X_p' X_E \beta_E) + (X_p' X_p)^{-1} (X_p' u) \\ &= \beta_p + (X_p' X_p)^{-1} (X_p' X_E) \beta_E + (X_p' X_p)^{-1} X_p' u \end{aligned}$$

امید ریاضی $\hat{\beta}_p$ عبارت است از:

$$E(\hat{\beta}_p) = \beta_p + (X_p' X_p)^{-1} (X_p' X_E) \beta_E \quad (9-23)$$

توجه شود که $(X_p' X_p)^{-1} (X_p' X_E)$ بیانگر ضرایب رگرسیون $K-p$ متغیر حذف شده از مدل (9-16) روی p متغیر X موجود در مدل (9-20) می‌باشد. بدین منظور، ضرایب آنها را با ماتریس b نشان می‌دهیم $(X_E = X_p b + v)$ که $\hat{b} = (X_p' X_p)^{-1} (X_p' X_E)$ می‌باشد. بنابراین b ماتریسی با ابعاد $p \times (K-p)$ می‌باشد که عبارت است از:

$$b = \begin{bmatrix} b_{1,p+1} & b_{1,p+2} & \dots & b_{1,K} \\ b_{2,p+1} & b_{2,p+2} & \dots & b_{2,K} \\ \vdots & \vdots & \dots & \vdots \\ b_{p,p+1} & b_{p,p+2} & \dots & b_{p,K} \end{bmatrix}_{p \times (K-p)}$$

بنابراین می‌توان (۶-۲۳) را به صورت زیر نوشت:

$$E(\hat{\beta}_p) = \beta_p + b\beta_E = [I_p \quad b] \begin{bmatrix} \beta_p \\ \beta_E \end{bmatrix} = [I_p \quad b]\beta$$

که $I_p = \begin{bmatrix} 1 & & \\ & \ddots & \\ & & 1 \end{bmatrix}$ می‌باشد. سطر نام رابطه فوق عبارت است از:

$$E(\hat{\beta}_{pi}) = \beta_i + b_{i,p+1}\beta_{p+1} + b_{i,p+2}\beta_{p+2} + \dots + b_{i,K}\beta_K, \quad i=1,2,\dots,p \quad (6-24)$$

بدین ترتیب مشاهده می‌شود که تخمین پارامترهایی که از معادله (۶-۲۰) به دست می‌آید، بدون تورش نمی‌باشند، زیرا $E(\hat{\beta}_{pi}) \neq \beta_i$ می‌باشد. فقط در صورتی این تخمین‌ها بدون تورش هستند که عناصر ماتریس b برابر با صفر باشند، یعنی متغیرهای حذف شده با متغیرهایی که در مدل مانده‌اند هیچ گونه رابطه خطی نداشته باشند. علاوه بر این، حذف متغیرهای مهم باعث می‌شود که برآورد واریانس رگرسیون (σ^2) نیز دارای تورش گردد. بدین ترتیب، تخمین انحراف معیار ضرایب نیز تورش خواهند داشت که موجب می‌شود تا نتیجه‌گیری‌هایی که در مورد پارامترها صورت می‌گیرد، دچار خدشه شوند.

اما می‌توان تأثیر «متغیر حذف شده» را آزمون نمود. البته این آزمون تا حدود زیادی مشابه با آزمون محدودیت‌ها است که در فصل سوم بحث شد. به عنوان مثال فرض کنید که Y تابعی از دو متغیر X_1 و X_2 است، ولی X_3 از مدل حذف شده است. در این حالت ضریب X_1 را برابر با صفر قرار داده‌ایم ($\beta_3 = 0$).

$$Y_i = \beta_1 + \beta_2 X_{1i} + \beta_3 X_{2i} + u_i \quad (6-25)$$

$$Y_i = \alpha_1 + \alpha_2 X_{1i} + v_i \quad (6-26)$$

معادله (۶-۲۵) و (۶-۲۶) به ترتیب رگرسیون‌های غیرمقید و مقید را نشان می‌دهد که ضریب تعیین آنها به ترتیب R_{UR}^2 و R_R^2 می‌باشد. برای آزمون این فرضیه، از F استفاده می‌کنیم که عبارت است از:

$$F_{1,n-K} = (n-K) \frac{R_{UR}^2 - R_R^2}{1 - R_{UR}^2} \quad (6-27)$$

توجه داریم که اگر در توزیع F درجه آزادی صورت برابر ۱ باشد، آنگاه F برابر با t است.


فایل data2

آزمون متغیرهای حذف شده با استفاده از Eviews

ابتدا مدل مورد نظر را که به عنوان مثال معادله (۶-۲۶) می باشد، برآورد می کنیم که نتایج آن در پنجره Equation نشان داده می شود. برای بررسی اثر متغیر حذف شده، به صورت زیر عمل می کنیم:

View → Coefficient Diagnostics → Omitted Variable Test

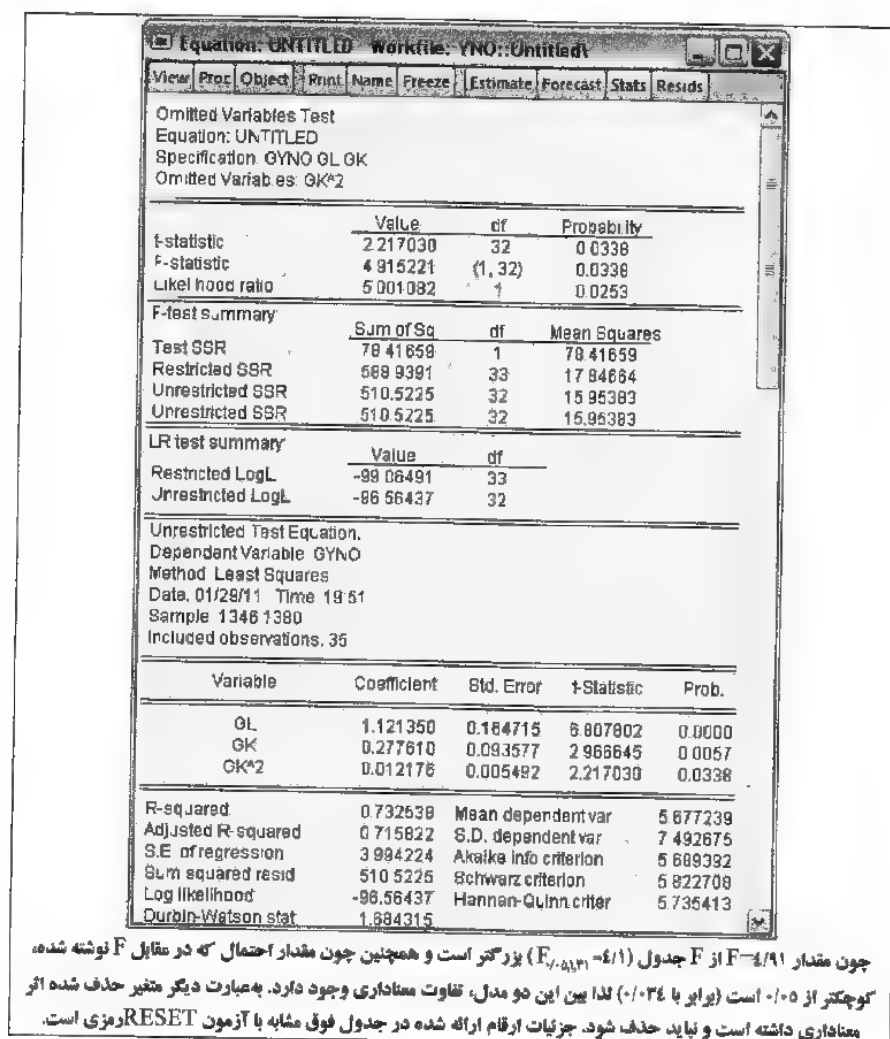
در این حالت پنجره‌ای به نام Omitted-Redundant Variable Test باز می شود، که در آن می توان نام متغیر یا متغیرهای حذف شده را وارد نمود.



بعد از وارد نمودن نام متغیرهای حذف شده (مثلاً X_p) و انتخاب OK، نتایج حاصل از تخمین مدل جدید (یعنی مدلی که به آن متغیرهای حذف شده، اضافه شده است) ارائه می شود. علاوه بر تخمین مدل جدید، برای آزمون فرضیه متغیرهای حذف شده، مقدار F و نسبت درست نمایی نیز داده می شود. اگر مقدار F بزرگتر از F جدول باشد یا مقدار احتمال که در مقابل F نوشته می شود کمتر از ۰/۰۵ باشد، در این صورت متغیرهای حذف شده اثر معنی داری داشته اند. به عنوان مثال در آزمون Reset رمز می دیدیم که مدل صحیح برای تبیین نرخ رشد تولید ناخالص داخلی به گونه ای است که بایستی توان دوم نرخ رشد سرمایه را نیز وارد کنیم. این موضوع را می توان از طریق آزمون متغیرهای حذف شده نیز بررسی نمود. بدین منظور ابتدا نرخ رشد تولید ناخالص داخلی بدون ثقت (GYNO) را روی نرخ رشد نیروی کار (GL) و نرخ رشد سرمایه (GK) پرازش می کنیم:

Equation: UNTITLED Workfile: YNO::Untitled				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: GYNO				
Method: Least Squares				
Date: 01/29/11 Time: 19:47				
Sample (adjusted): 1346 1380				
Included observations: 35 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GL	1.107676	0.174091	6.362644	0.0000
GK	0.418728	0.072549	5.771668	0.0000
R-squared	0.891456	Mean dependent var	5.677239	
Adjusted R-squared	0.882106	S.D. dependent var	7.492675	
S.E. of regression	4.224529	Akaike info criterion	5.775138	
Sum squared resid	588.9391	Schwarz criterion	5.884016	
Log likelihood	-99.06491	Hannan-Quinn criter.	5.805818	
Durbin-Watson stat	1.578005			

در پنجره فوق، به طریقی که گفته شد اثر متغیر حذف شده (یعنی توان دوم نرخ رشد سرمایه) را بررسی می کنیم. نتایج حاصله عبارت است از:



۶-۵ ورود متغیرهای نامربوط

در اینجا بر خلاف حذف متغیرهای مهم، برخی متغیرهایی که ضرورتی ندارند وارد مدل شده‌اند. به عنوان مثال فرض کنید که مدل صحیح به صورت زیر باشد:

$$Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \beta_4 X_{3t} + u_t \quad (6-28)$$

اما به جای (۶-۲۸) مدل زیر را برآورد می‌کنیم که شامل متغیر نامربوط X_4 می‌باشد:

$$Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \beta_4 X_{3t} + \beta_5 X_{4t} + u_t \quad (6-29)$$

از آنجا که X_6 یک متغیر نامربوط و غیر ضروری است لذا انتظار داریم که β_6 برابر با صفر باشد. پیامد ورود چنین متغیری این است که سایر ضرایب هنوز سازگار و بدون تورش هستند. اما تخمین‌زنده‌ها را ناکارآمد می‌کند و این موجب می‌شود که انحراف معیار تخمین‌زنده‌ها بزرگ شود. اما به‌طور کلی میزان کاهش در کارایی تخمین‌زنده‌ها بستگی به قدر مطلق ضریب همبستگی بین متغیر نامربوط و سایر متغیرهای توضیحی دارد. زیرا واریانس تخمین‌زنده‌ها رابطه مستقیم با مجذور ضریب همبستگی بین متغیرهای توضیحی دارد. به‌طور کلی اگر متغیر نامربوطی را وارد مدل کنیم که در عین حال با بقیه متغیرهای موجود در مدل ایجاد همخطی نماید، باعث کاهش کارایی تخمین‌زنده‌ها می‌گردد.

فایل data2

آزمون متغیرهای نامربوط با استفاده از Eviews

مراحل انجام این آزمون دقیقاً مشابه با آزمون متغیرهای حذف شده است. ولی توجه داشته باشیم که در اینجا نام متغیرهایی را وارد می‌کنیم که بایستی از مدل حذف شوند. به‌عنوان مثال ابتدا مدل (۶-۲۹) را تخمین می‌زنیم و سپس در پنجره‌ای که نتایج تخمین نشان داده شده است از طریق View → Coefficient Diagnostics → Redundant Variable Test آن، نام متغیرهای نامربوط را وارد می‌کنیم و با انتخاب OK نتایج مورد نظر به دست می‌آید. نتایج حاصل از پرآورد مدل جدید به همراه مقدار F و احتمال آن نیز داده می‌شود. در اینجا نیز اگر مقدار F بزرگتر از F جدول و با احتمال‌های آن کمتر از ۰.۰۵ باشد در این صورت متغیری را که از مدل اولیه کنار می‌گذاریم یک متغیر نامربوط و زائد نیست و بایستی در مدل حفظ شود.

به‌عنوان مثال معادله سرمایه‌گذاری خصوصی (IP) روی نرخ بهره حقیقی (RR) و درآمد ملی (Y) برازش شده است. نتیجه عبارت است از:

Equation: UNTITLED Workfile: 53: Untitled				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: IP				
Method: Least Squares				
Date: 10/13/11 Time: 15:58				
Sample: 1345 1380				
Included observations: 36				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-7386.982	5077.892	-1.454791	0.1552
RR	97.82949	185.7167	0.590342	0.5590
Y	0.159006	0.023502	6.766674	0.0000
R-squared	0.582922	Mean dependent var		25513.35
Adjusted R-squared	0.557645	S.D. dependent var		13267.30
S.E. of regression	8817.405	Akaike info criterion		21.08650
Sum squared resid	2.57E+09	Schwarz criterion		21.21046
Log likelihood	-378.6570	Hannan-Quinn criter.		21.13256
F-statistic	23.06096	Durbin-Watson stat		1.063640
Prob(F-statistic)	0.000001			

حال بررسی می‌کنیم که آیا نرخ بهره (RR) یک متغیر زائد است یا خیر. بدین منظور، در پنجره فوق، مسیر

۶-۶ آزمون‌های ثبات ضرایب

معادله رگرسیون زیر را در نظر بگیرید:

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t \quad (6-30)$$

فرض ضمنی در این معادله این است که ضرایب β_1 ، β_2 و β_3 ثابت هستند. به عبارت دیگر این ضرایب چه در کل دوره مورد بررسی برآورد شوند و چه در بخشی از دوره مورد بررسی برآورد گردند، نتایج یکسانی به دست خواهد آمد. به عنوان مثال اگر معادله‌ای برای دوره ۸۰-۱۳۳۸ برآورد می‌کنیم ضرایب این معادله برای کل این دوره همان چیزی است که در دوره قبل و بعد از انقلاب به دست می‌آید.

اما این فرض را می‌توان در معرض آزمون قرار داد، زیرا ممکن است چنین فرضی برقرار نباشد. بدین منظور می‌توان کل دوره مورد مطالعه را به دو دوره و یا چند دوره تقسیم نمود و فرض ثبات ضرایب را مورد بررسی و آزمون قرار داد. یکی از آزمون‌های تغییر ضرایب، معروف به آزمون چاو است که در اینجا روش انجام این آزمون را بررسی می‌کنیم. روش دیگر، استفاده از متغیرهای مجازی است که در ادامه بررسی خواهد شد.

۶-۶-۱ آزمون نقطه شکست چاو^۱

مراحل انجام آزمون چاو عبارت است از:

۱- دوره مورد مطالعه را به دو دوره تقسیم می‌کنیم که دوره اول و دوم به ترتیب شامل n_1 و n_2 مشاهده می‌باشند ($n_1 + n_2 = n$).

۲- رگرسیون مورد نظر را برای دوره اول و دوره دوم برآورد می‌کنیم. مجموع مجذور خطا برای دوره اول را با RSS_1 و برای دوره دوم با RSS_2 نشان می‌دهیم و مجموع این دو را $RSS_{UR} = RSS_1 + RSS_2$ می‌نامیم که بیانگر رگرسیون غیرمقید است، زیرا ضرایب آزاد هستند تا در این دو دوره، متفاوت باشند. درجه آزادی RSS_1 و RSS_2 به ترتیب برابر با $n_1 - K$ و $n_2 - K$ می‌باشد و لذا درجه آزادی RSS_{UR} نیز برابر با $n - 2K$ خواهد بود.

^۱Chow breakpoint test

۳- معادله مورد نظر را برای کل دوره برآورد کرده و مجموع مجذور باقیمانده‌های آن را با $RSS_R = RSS$ نشان می‌دهیم که بیانگر رگرسیون مقید است، زیرا ضرایب در هر دو دوره یکسان در نظر گرفته شده‌اند. درجه آزادی RSS_R برابر با $n-K$ است.

۴- برای بررسی تغییر ساختاری، بایستی RSS_{UR} و RSS_R را مقایسه کنیم. بدین منظور از نسبت F استفاده می‌کنیم:

$$F_{K, n-2K} = \frac{n-2K}{K} \frac{RSS_R - RSS_{UR}}{RSS_{UR}} = \frac{n-2K}{K} \frac{RSS - (RSS_1 + RSS_2)}{RSS_1 + RSS_2} \quad (6-31)$$

تفاوت رگرسیون مقید و غیرمقید، فقط در ضرایب آنها است. اگر ضرایب باثبات باشند در این صورت تفاوت چندانی بین RSS و $RSS_1 + RSS_2$ وجود ندارد و لذا مقدار F نیز کوچک می‌شود، در غیر این صورت مقدار F بزرگ شده و فرضیه ثبات ضرایب رد می‌شود.

آزمون نقطه شکست چاو در Eviews

فایل data2

تصور کنید که می‌خواهیم نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) را روی نرخ رشد کار (GL) و نرخ رشد سرمایه (GK) برازش کنیم. بدین منظور ابتدا معادله مورد نظر را برای دوره ۸۰-۱۳۶۶ برآورد می‌کنیم که حجم نمونه $n=35$ می‌باشد. نتایج تخمین عبارت است از:

$$GYNO = 1.107GL + 0.419GK \quad R^2 = 0.691 \quad R^2 = 0.682$$

(6.4) (5.8) $RSS = 588.94$

توجه شود که در پنجره نتایج، RSS با Sum squared resid نشان داده شده است. حال می‌خواهیم ثبات ضرایب نیروی کار و سرمایه طی دوره مورد نظر را بررسی کنیم. بدین منظور دوره قبل و بعد از انقلاب را در نظر می‌گیریم. برای انجام آزمون چاو، در پنجره نتایج تخمین، به صورت زیر عمل می‌کنیم:

View → Stability Diagnostics → Chow Breakpoint Test

در پنجره Chow Test سال شروع دوره دوم را وارد کنیم (در این مثال سال ۱۳۵۷ می‌باشد):



در پنجره فوق، متغیرهای توضیحی و همچنین عرض از مبدأ را می‌توان وارد نمود. اگر فقط C را بنویسیم، آنگاه فقط تغییر در عرض از مبدأ را لحاظ می‌کند. اما اگر C و GL را بنویسیم، آنگاه تغییر در عرض از مبدأ و ضریب GL را

لحاظ می‌کند. همچنین اگر تمام متغیرها را بنویسیم، در این صورت تغییر تمام ضرایب را لحاظ کرده و آزمون می‌کند. با انتخاب OK، نتایج آزمون چاو به صورت زیر نشان داده می‌شود:

Equation: UNTITLED Workbook: TNO: Untitled

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
------	------	--------	-------	------	--------	----------	----------	-------	--------

Chow Forecast Test
Equation: UNTITLED
Specification: GYNO GLOK
Test predictions for observations from 1357 to 1390

	Value	df	Probability
F-statistic	0.420224	(24, 9)	0.9565
Likelihood ratio	28.30943	24	0.3377

F-test summary

	Sum of Sq	df	Mean Squares
Test SSR	311.2160	24	12.96733
Restricted SSR	688.9391	33	17.84664
Unrestricted SSR	277.7231	9	30.85813
Unrestricted SSR	277.7231	9	30.85813

LR test summary

	Value	df
Restricted LogL	-99.08491	33
Unrestricted LogL	-85.91019	9

Unrestricted log likelihood adjusts test equation results to account for observations in forecast sample

Unrestricted Test Equation
Dependent Variable: GYNO
Method: Least Squares
Date: 01/29/11 Time: 20:51
Sample: 1348 1356
included observations: 11

Variable	Coefficient	Std. Error	t-Statistic	Prob
GL	1.415792	0.465405	3.042062	0.0140
GK	0.481837	0.127818	3.770482	0.0044

R-squared	0.458899	Mean dependent var	12.18188
Adjusted R-squared	0.398777	S.D. dependent var	7.164186
S.E. of regression	5.555009	Akaike info criterion	6.430243
Sum squared resid	277.7231	Schwarz criterion	6.502587
Log likelihood	-33.36634	Hannan-Quinn criter.	6.384640
Durbin-Watson stat	1.152511		

با توجه به مقدار F از F جدول کوچکتر است و همچنین احتمال آن که از ۰/۰۵ بزرگتر است، فرضیه ثبات ضرایب رد نمی‌شود. لذا ضرایب این معادله، در دوره‌های قبل و بعد از انقلاب، متفاوت نیست.

توجه شود که آزمون چاو را می‌توان برای چند دوره نیز انجام داد. به عنوان مثال اگر بخواهیم، آزمون ثبات ضرایب را برای دوره‌های ۵۶-۱۳۴۶، ۷۰-۱۳۵۷ و ۸۰-۱۳۷۱ انجام دهیم، لازم است که در پنجره مورد نظر، به ترتیب سال ۱۳۵۷ (سال شروع دوره دوم) و سال ۱۳۷۱ (سال شروع دوره سوم) را وارد نماییم.

۶-۲-۶ آزمون پیش‌بینی چاو^۱

آزمون پیش‌بینی چاو بر این اساس است که اگر ضرایب با ثبات باشند، خطای پیش‌بینی کوچک خواهد بود. بدین منظور کل داده‌ها را به دو دوره تقسیم می‌کنیم: دوره اول با n_1 مشاهده و دوره دوم با n_2 مشاهده. دوره اول را برای تخمین و دوره دوم را برای پیش‌بینی در نظر

^۱Chow forecast test

می‌گیریم. اگر ضرایب با ثبات باشند، بایستی متوسط خطای پیش‌بینی در دوره دوم (σ_f^2) و متوسط خطای رگرسیون در دوره اول (σ^2)، تقریباً یکسان باشند. بنابراین، فرضیه ثبات ضرایب به صورت $H_0: \sigma^2 = \sigma_f^2$ می‌باشد. در غیر این صورت، رگرسیون دچار شکستگی شده است و لذا رگرسیون بر اساس داده‌های گذشته، نمی‌تواند مقادیر آینده را به خوبی پیش‌بینی کند. بدین منظور، مراحل زیر را انجام می‌دهیم:

۱- معادله $Y_t = \alpha + \beta X_t + u_t$ را برای n_1 مشاهده اول (دوره اول) برآورد کرده و مجموع مجذور باقیمانده را با RSS_1 نشان می‌دهیم.

$$RSS_1 = \sum_{i=1}^{n_1} (Y_i - \hat{Y}_i)^2, \quad \hat{\sigma}^2 = \frac{RSS_1}{n_1 - K} \quad (6-32)$$

۲- برای دوره دوم که از سال $n_1 + 1$ تا n می‌باشد، مقادیر Y_t را با استفاده از رگرسیون برآوردی در مرحله ۱، پیش‌بینی می‌کنیم:

$$Y_t^f = \hat{\alpha} + \hat{\beta} X_t \quad ; \quad t = n_1 + 1, \dots, n \quad (6-33)$$

۳- خطاهای پیش‌بینی را به صورت زیر برای دوره دوم حساب می‌کنیم:

$$\begin{aligned} e_t^f &= Y_t - Y_t^f \\ &= (\alpha + \beta X_t + u_t) - (\hat{\alpha} + \hat{\beta} X_t) \\ &= -(\hat{\alpha} - \alpha) - (\hat{\beta} - \beta) X_t + u_t \quad ; \quad t = n_1 + 1, \dots, n \end{aligned} \quad (6-34)$$

امید ریاضی و واریانس خطای پیش‌بینی عبارت است از (به بخش ۱۴-۲ مراجعه شود):

$$\begin{aligned} E(e_t^f) &= 0 \\ \text{var}(e_t^f) &= \sigma^2 \left(1 + \frac{1}{n} + \frac{(X_t - \bar{X})^2}{\sum_{t=n_1+1}^n X_t^2} \right) \end{aligned} \quad (6-35)$$

همچنین مجموع مجذور خطاهای پیش‌بینی و میانگین خطای پیش‌بینی عبارت است از:

$$RSS_f = \sum_{t=n_1+1}^n (Y_t - Y_t^f)^2, \quad \hat{\sigma}_f^2 = \frac{RSS_f}{n_f} \quad (6-36)$$

توجه شود که در اینجا، درجه آزادی برابر با n_1 است، زیرا برای محاسبه RSS_f هیچ ضریبی را برآورد نکرده‌ایم.

۴- در صورتی که ضرایب ثابت باشند نباید تفاوت معناداری بین $\hat{\sigma}^2$ و $\hat{\sigma}_f^2$ باشد. برای آزمون فرضیه $H_0: \sigma^2 = \sigma_f^2$ ، آماره F را تشکیل می‌دهیم:

$$F_{n_1, n_1-K} = \frac{\chi_{n_1}^2 / n_1}{\chi_{n_1-K}^2 / (n_1 - K)} = \frac{\hat{\sigma}_f^2 / \sigma_f^2}{\hat{\sigma}^2 / \sigma_f^2} \quad (6-37)$$

تحت فرضیه H_0 ، آماره F عبارت است از:

$$F_{n_1, n_1-K} = \frac{\hat{\sigma}_f^2 / \sigma_f^2}{\hat{\sigma}^2 / \sigma_f^2} \bigg|_{H_0} = \frac{\hat{\sigma}_f^2}{\hat{\sigma}^2} \quad (6-38)$$

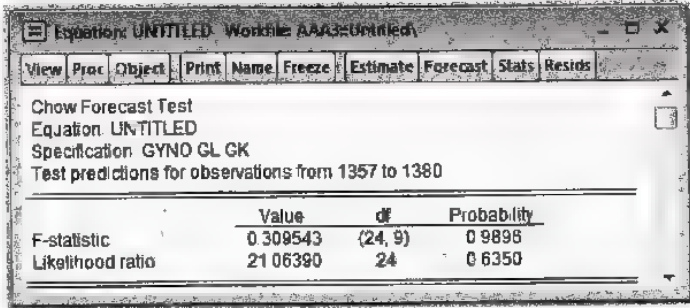
$$= \frac{RSS_f / n_1}{RSS / (n_1 - K)} = \frac{n_1 - K}{n_1} \frac{RSS_f}{RSS}$$

اگر فرضیه H_0 درست باشد، مقدار F کوچک خواهد بود و در ناحیه بحرانی قرار نمی‌گیرد و لذا ضرایب باثبات خواهند بود.

آزمون پیش‌بینی چاو در Eviews

فایل data2

ابتدا معادله را برای کل دوره برآورد کرده و سپس مشابه آزمون چاو عمل می‌کنیم، با این تفاوت که به جای گزینه Chow Breakpoint Test گزینه Chow Forecast Test را انتخاب می‌کنیم. نتایج در پنجره‌ای به صورت زیر نشان داده می‌شود.



	Value	df	Probability
F-statistic	0.309543	(24, 9)	0.9898
Likelihood ratio	21.06390	24	0.6350

چون مقدار F کوچک است و در ناحیه بحرانی قرار ندارد، لذا فرضیه ثبات ضرایب رد نمی‌شود.

۶-۶-۳ آزمون‌های بازگشتی

آزمون‌های بازگشتی مبتنی بر برآورد ضرایب برای دوره‌های مختلف است. لذا این روش‌ها حالت عمومی‌تری از آزمون چاو هستند. اگر دوره‌ها را با s نشان دهیم، دوره اول شامل K مشاهده اول (K تعداد متغیرهای توضیحی است)، دوره دوم شامل $K+1$ مشاهده بعدی و دوره آخر شامل کل مشاهدات (n) است. بنابراین، برآورد ضرایب رگرسیون ساده، عبارت است از:

$$\hat{\alpha}_s = \bar{Y}_s - \hat{\beta}_s \bar{X}_s, \quad \hat{\beta}_s = \frac{\sum_{t=1}^s x_t y_t}{\sum_{t=1}^s x_t^2}; \quad s = K, K+1, \dots, n \quad (6-39)$$

$$\bar{Y}_s = \frac{\sum_{t=1}^s Y_t}{s}, \quad \bar{X}_s = \frac{\sum_{t=1}^s X_t}{s}$$

در حالت کلی (رگرسیون K متغیره) می‌توان تخمین‌های بازگشتی را به صورت زیر نشان داد:

$$\hat{\beta}_s = (X_s' X_s)^{-1} X_s' y_s; \quad s = K, K+1, \dots, n \quad (6-40)$$

از طرف دیگر به ازای هر یک از برآوردهای بازگشتی، RSS_s را محاسبه می‌کنیم:

$$RSS_s = \sum_{t=1}^s (Y_t - \hat{Y}_t)^2 = \sum_{t=1}^s (Y_t - \hat{\alpha}_s - \hat{\beta}_s X_t)^2; \quad s = K+1, \dots, n \quad (6-41)$$

بدیهی است که به ازای $s=K$ ، مقدار RSS_s برابر صفر است (چرا؟).

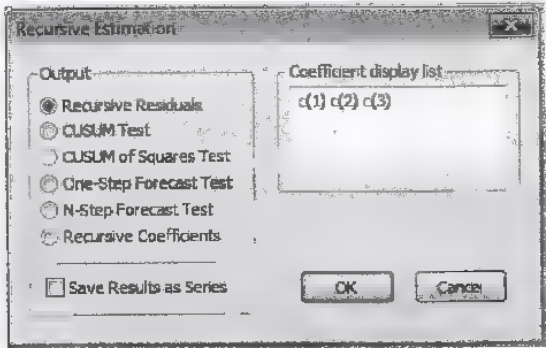
حال اگر ضرایب بازگشتی یا RSS های بازگشتی را محاسبه و ترسیم کنیم، روند آنها نشان می‌دهد که در چه سالی تغییر ضرایب رخ داده است. معمولاً نرم‌افزارهایی مانند Eviews این محاسبات را انجام داده و نمودار آنها را همراه با «به اضافه و منهای دو انحراف معیار» ترسیم می‌کند. اگر RSS ها از این مرزها عبور کنند نشان‌دهنده تغییرات ساختاری است.

برآوردهای بازگشتی در Eviews

فایل data2


ابتدا معادله مورد نظر را برآورد می‌کنیم و در پنجره نتایج، مسیر زیر را دنبال می‌کنیم:
View → Stability Diagnostics → Recursive Estimates (OLS only)

پنجره زیر باز می‌شود (معادله برآوردی یا اگر رگرسیون نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) روی عرض از مبدأ، نرخ رشد نیروی کار (GL) و نرخ رشد موجودی سرمایه (GK) می‌باشد):






در پنجره فوق، گزینه Recursive Residuals نمودار و مرز RSS های بازگشتی را رسم می‌کند. همچنین، گزینه آخر، یعنی Recursive Coefficients، نمودار و مرز هر یک از ضرایب را رسم می‌کند. دو سمت راست پنجره فوق، می‌توان هر

یکه از ضرایب را انتخاب نموده و نمودارهای مربوطه را ترسیم نمود. به عنوان نمونه، RSSهای بازگشتی برای همه ضرایب عبارت است از:



در سال ۱۳۵۲، ۱۳۵۶ و ۱۳۵۹ تغییر ساختاری رخ داده است، زیرا RSSها از مرز خارج شده‌اند. برای هر یک از ضرایب، نمودارهای زیر به دست آمده است و نشان می‌دهد که ضرایب $C(1)$ ، $C(2)$ و $C(3)$ از سال ۱۳۵۸ به بعد تقریباً با ثبات بوده‌اند.





۶-۶-۱ پیش‌بینی یک‌قدمی

روش پیش‌بینی یک‌قدمی شیوه دیگری برای بررسی شکست ساختاری و تغییر ضرایب است. در این روش، ضرایب بر اساس داده‌های یک دوره تخمین زده می‌شوند و سپس مقدار Y برای سال بعد پیش‌بینی می‌شود. بدین منظور فرض کنید که حجم مشاهدات برابر با n باشد. معادله را برای s مشاهده اول، برآورد می‌کنیم:

$$\hat{Y}_t = \hat{\alpha}_s + \hat{\beta}_s X_t; \quad t=1, \dots, s, \quad s \geq K$$

$$\hat{\alpha}_s = \bar{Y}_s - \hat{\beta}_s \bar{X}_s, \quad \hat{\beta}_s = \frac{\sum_{t=1}^s x_t y_t}{\sum_{t=1}^s x_t^2}; \quad \bar{Y}_s = \frac{\sum_{t=1}^s Y_t}{s}, \quad \bar{X}_s = \frac{\sum_{t=1}^s X_t}{s} \quad (6-42)$$

اگر $s = t-1$ باشد، خطای پیش‌بینی یک‌قدمی (یک‌دوره‌ای) برابر است با:

$$e_t^f = Y_t - Y_t^f = Y_t - \hat{\alpha}_s - \hat{\beta}_s X_t; \quad s = t-1 \quad (6-43)$$

واریانس خطای پیش‌بینی یک‌قدمی عبارت است از (به بخش ۱۴-۲ مراجعه شود):^۱

$$\text{var}(e_t^f) = \text{var}(Y_t - Y_t^f) = \text{var}(Y_t - \hat{\alpha}_s - \hat{\beta}_s X_t)$$

$$= \sigma^2 \left(1 + \frac{1}{n} + (X_t - \bar{X}_s)' / \sum_{t=1}^s x_t^2 \right); \quad s = t-1 \quad (6-44)$$

^۱ در حالت K متغیره روابط زیر را داریم:

$$Y_t = \sum_{k=1}^K X_{kt} + u_t = (1 \quad X_{t1} \quad \dots \quad X_{tK}) \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} + u_t = \mathbf{z}_t' \boldsymbol{\beta} + u_t$$

\mathbf{z}_t بردار ستونی است که مشاهدات سال t را برای متغیرهای توضیحی نشان می‌دهد. Y_t مقدار Y در سال t است. شکل ماتریسی رابطه فوق عبارت است از:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}, \quad \hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

اگر $\hat{\boldsymbol{\beta}}$ را برای داده‌های $s = 1, \dots, t$ بنویسیم، آن را به صورت زیر نشان می‌دهیم:

$$\hat{\boldsymbol{\beta}}_s = (\mathbf{X}_s' \mathbf{X}_s)^{-1} \mathbf{X}_s' \mathbf{y}_s; \quad s = K, K+1, \dots, t-1$$

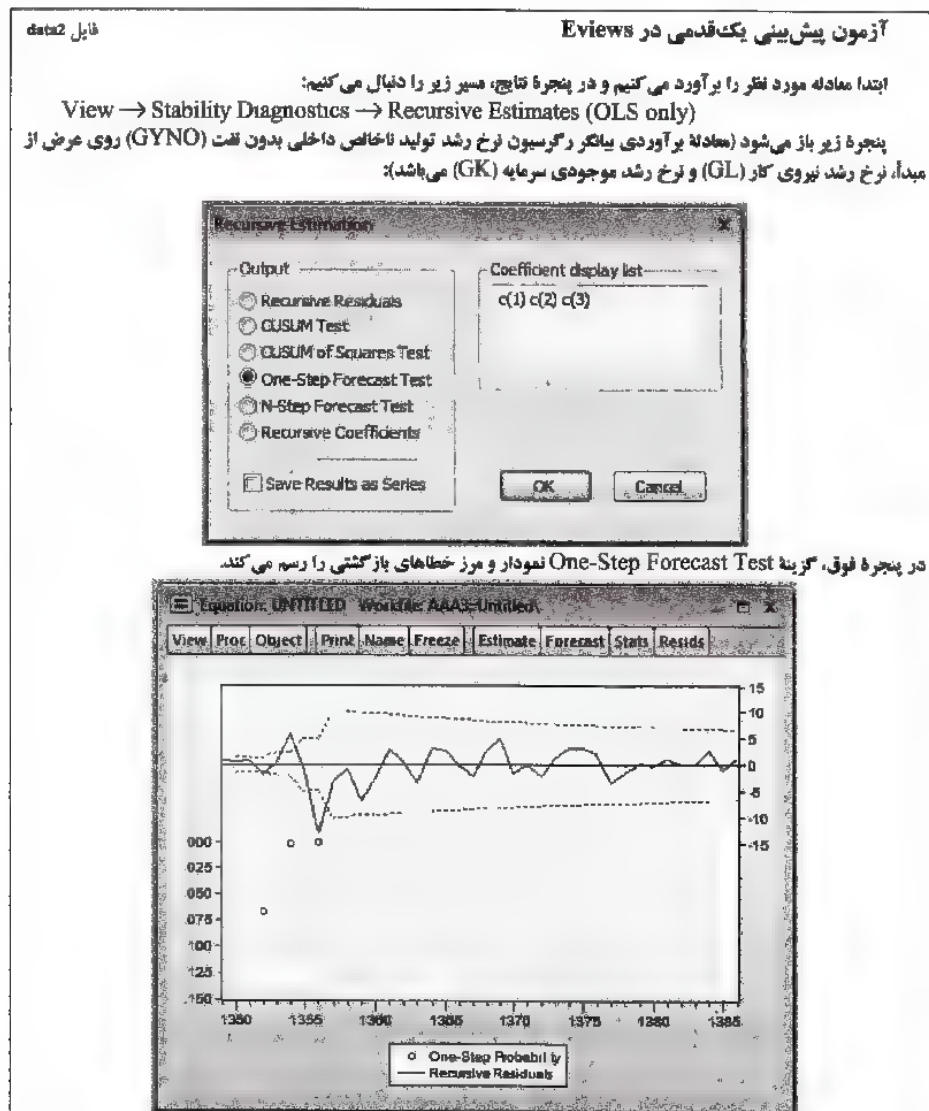
خطای پیش‌بینی یک‌قدمی برابر است با:

$$e_t^f = Y_t - Y_t^f = Y_t - \mathbf{z}_t' \hat{\boldsymbol{\beta}}_s; \quad s = t-1$$

واریانس خطای پیش‌بینی یک‌قدمی عبارت است:

$$\text{var}(e_t^f) = \text{var}(Y_t - Y_t^f) = \sigma^2 \left(1 + \mathbf{z}_t' (\mathbf{X}_s' \mathbf{X}_s)^{-1} \mathbf{z}_t \right)$$

σ^2 مجهول است که به جای آن از واریانس جملات خطاهای ε مشاهده اول استفاده می‌کنیم. با محاسبه انحراف معیار خطای پیش‌بینی، می‌توان «به‌اضافه و منهای دو برابر انحراف معیار» را نیز حساب نمود. در هر سالی که خطای پیش‌بینی از این مرز (به‌اضافه و منهای دو برابر انحراف معیار) خارج شود، بیانگر عدم ثبات ضرایب است. در واقع اگر t نزدیک به صفر باشد، ضرایب باثبات هستند و به همین دلیل، خطای پیش‌بینی نیز ناچیز خواهد بود.



نمودار فوق نشان می‌دهد که در برخی از سالها (در اینجا سه سال)، خطاهای پیش‌بینی یک‌قدمی، از مرزها فراتر رفته است. محور عمودی سمت راست، مقدار خطاها و مرزها را نشان می‌دهد. محور عمودی سمت چپ، مقدار احتمال نقاطی که از مرز خارج شده‌اند را نشان می‌دهند. مثلاً در سال ۱۳۵۶ که خارج از مرز است، احتمال آن ۰/۰۰۱ است (اگر نشانگر ماوس را روی نقطه موردنظر تکه دارید، سال و مقدار احتمال را مشخص می‌کند). همچنین در سال ۱۳۵۲ احتمال برآورد با ۰/۰۰۲۵ و در سال ۱۳۵۲ احتمال برآورد با ۰/۰۶۷۱ است. بنابراین، تغییر ضرایب در سال ۱۳۵۴ و ۱۳۵۶ در سطح ۰/۰۵ و حتی در سطح ۰/۰۱ معنادار است، اما در سال ۱۳۵۲ در سطح ۰/۰۶۷ درصد.

۶-۱-۵ آزمون مجموع تجمعی خطاهای بازگشتی (CUSUM)

در مبحث پیش‌بینی یک‌قدمی برای سال t دیدیم که خطای پیش‌بینی و واریانس آن عبارت است از:

$$e_t^f = Y_t - Y_t^f = Y_t - \hat{\alpha}_s - \hat{\beta}_s X_t \quad ; \quad s = t-1$$

$$\text{var}(e_t^f) = \sigma^2 \left(1 + \frac{1}{n} + \frac{(X_t - \bar{X}_s)^2}{\sum_{i=1}^s x_i^2} \right) \quad ; \quad s = t-1 \quad (6-45)$$

حال خطاهای بازگشتی را به صورت زیر می‌نویسیم:

$$w_t = \frac{e_t^f}{\sqrt{1 + \frac{1}{n} + \frac{(X_t - \bar{X}_s)^2}{\sum_{i=1}^s x_i^2}}} \quad ; \quad s = t-1, \quad t = K+1, \dots, n \quad (6-46)$$

w_t توزیع نرمال با میانگین صفر و واریانس σ^2 دارد. حال w_t ها را استاندارد کرده و مقدار تجمعی آنها را حساب می‌کنیم:

$$W_t = \sum_{j=K+1}^t \frac{w_j}{\hat{\sigma}} \quad ; \quad t = K+1, \dots, n, \quad \hat{\sigma}^2 = \frac{RSS_n}{n-K} \quad (6-47)$$

RSS_n مجموع مجذور خطاها برای معادله‌ای است که با تمامی مشاهدات برازش شده است. اگر ضرایب باثبات باشند، در این صورت خطای پیش‌بینی ناچیز است و لذا مجموع تجمعی آنها نیز کوچک خواهد بود و در نتیجه، W_t نزدیک به صفر می‌باشد (یعنی نزدیک به امید ریاضی آن، زیرا $E(W_t) = 0$ است). در غیر این صورت، W_t تفاوت معناداری با صفر خواهد داشت. برای آزمون W_t مرزهایی تعیین می‌شود که اگر W_t از این مرزها عبور کند نشان‌دهنده تغییر ضرایب

می‌باشد. مختصات شروع این مرزها برابر با $(K, \pm a\sqrt{n-K})$ و مختصات نقطه پایان آن برابر با $(n, \pm 2a\sqrt{n-K})$ می‌باشد.

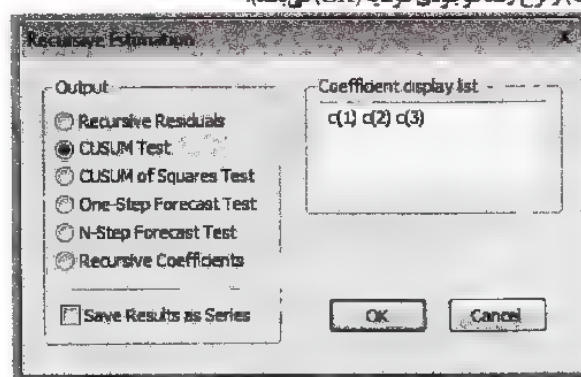
فایل data2

آزمون مجموع تجمعی خطاها (CUSUM) در Eviews


ابتدا معادله مورد نظر را برآورد می‌کنیم و در پنجره نتایج، مسیر زیر را دنبال می‌کنیم:

View → Stability Diagnostics → Recursive Estimates (OLS only)

پنجره زیر باز می‌شود (معادله برآوردی بیانگر رگرسیون نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) روی عرض از مبدا، نرخ رشد نیروی کار (GL) و نرخ رشد موجودی سرمایه (GK) می‌باشد):



در پنجره فوق، گزینه CUSUM Test را انتخاب می‌کنیم. نمودار و مرز خطاهای تجمعی بازگشتی به صورت زیر ترسیم می‌شود.



نمودار فوق نشان می‌دهد که هیچ یک از خطاهای تجمعی از مرزها خارج نشده‌اند و لذا این آزمون هیچ گونه تغییر ساختاری را نشان نمی‌دهد.

۶-۶-۶ آزمون مجموع مجدور تجمعی خطاهای بازگشتی (CUSUMQ)

در این روش، از نسبت زیر استفاده می‌شود:

$$S_t = \frac{\sum_{j=K+1}^t w_j^2}{\sum_{j=K+1}^n w_j^2} \quad ; \quad t = K+1, \dots, n \quad (6-48)$$

هر یک از w_t ها تحت فرضیه H_0 (فرضیه ثبات ضرایب) دارای توزیع χ_1^2 هستند. امید ریاضی S_t برابر با $E(S_t) = \frac{t-K}{n-K}$ می‌باشد که بین صفر و ۱ است. اگر انحراف از میانگین، زیاد باشد در این صورت، تغییر ضرایب رخ داده است. مرزها نیز توسط نرم‌افزارهایی مانند Eviews ترسیم می‌شود. مرزها به صورت $E(S_t) \pm C$ می‌باشد که مقدار C بستگی به سطح معناداری دارد.

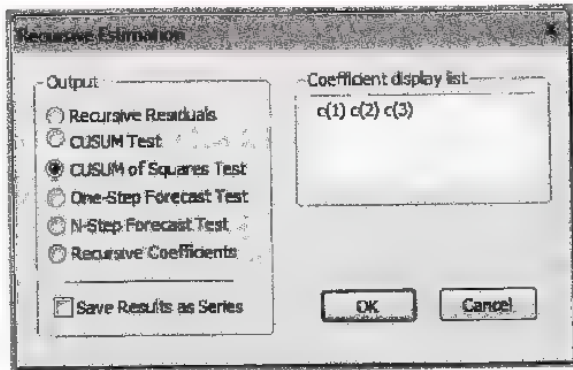
آزمون مجموع مجدور تجمعی خطاهای بازگشتی (CUSUMQ) در Eviews

فایل data2


ابتدا معادله مورد نظر را برآورد می‌کنیم و در پنجره نتایج، مسیر زیر را دنبال می‌کنیم:

View → Stability Diagnostics → Recursive Estimates (OLS only)

پنجره زیر باز می‌شود (معادله برآوردی یانگتر رگرسیون نرخ رشد تولید ناخالص داخلی بدون نفت (GYNO) روی عرض از مبدا، نرخ رشد نیروی کار (GL) و نرخ رشد موجودی سرمایه (GK) می‌باشد):



در پنجره فوق، گزینه CUSUM of Squares Test را انتخاب می‌کنیم. نمودار و مرز مجدور خطاهای تجمعی بازگشتی به صورت زیر ترسیم می‌شود.



نمودار فوق نشان می‌دهد که چون مجموع مجذور خطاهای تجمعی از مرزها خارج شده‌اند، لذا تغییر ساختاری رخ داده است.

۶-۶-۲ متغیرهای مجازی^۱ و آزمون ثبات ضرایب

فرضیه ثبات پارامترها را می‌توان با استفاده از متغیرهای مجازی نیز انجام داد. بدین منظور فرض کنید که مدل (۶-۳۰) را داشته باشیم. کل دوره مورد مطالعه را به دو دوره تقسیم می‌کنیم که دوره اول شامل n_1 مشاهده و در دوره دوم شامل n_2 مشاهده می‌باشد ($n_1 + n_2 = n$). مدل (۶-۳۰) بیانگر رگرسیون مقید است که برای کل دوره برآورد می‌شود. اما رگرسیون غیرمقید را برای کل دوره به صورت زیر تعریف می‌کنیم:

$$Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + \beta_4 D_t + \beta_5 D_t X_{1t} + \beta_6 D_t X_{2t} + u_t \quad (6-49)$$

D_t متغیر مجازی است که مقدار آن در دوره اول برابر با ۱ و در دوره دوم برابر با صفر است. اگر قید $\beta_4 = \beta_5 = \beta_6 = 0$ را اعمال کنیم، معادله (۶-۴۹) تبدیل به (۶-۳۰) خواهد شد. اگر ضرایب در طی دوره اول و دوم ثابت باشند، در این صورت ضرایب β_4 ، β_5 و β_6 از نظر آماری معنادار نخواهند بود.

$$\text{دوره اول: } D_t = 1 \Rightarrow Y_t = (\beta_1 + \beta_4) + (\beta_2 + \beta_5)X_{1t} + (\beta_3 + \beta_6)X_{2t} + u_t$$

$$\text{دوره دوم: } D_t = 0 \Rightarrow Y_t = \beta_1 + \beta_2 X_{1t} + \beta_3 X_{2t} + u_t$$

^۱ جزئیات بیشتر در فصل پنجم ارائه شده است.

آزمون ثبات ضرایب با استفاده از متغیرهای مجازی در Eviews

فایل data2

آزمون ثبات ضرایب تابع سرمایه‌گذاری خصوصی (IP) را با استفاده از متغیرهای مجازی انجام می‌دهیم. در اینجا دو دوره قبل و بعد از انقلاب را مقایسه می‌کنیم. بدین منظور ابتدا متغیر مجازی D57 را تعریف می‌کنیم که مقدار آن برای سالهای ۱۳۴۶-۵۶ برابر با ۱ و برای سالهای ۱۳۵۷-۸۰ برابر با صفر می‌باشد. حال مدل مورد نظر را با دستور زیر برآورد می‌کنیم:

$$LS \quad IP \ C \ Y \ R \ D57 \ D57*Y \ D57*R$$

توجه شود که این مدل مشابه مدل (۶-۳۲) است که در آن C مقدار ثابت است که برای β_0 می‌باشد. همچنین β_1 و β_2 یا β_3 ضرایب Y و R هستند. اما β_0 ، β_1 و β_2 به ترتیب ضرایب متغیرهای D57، D57*Y و D57*R می‌باشد. با برآورد مدل فوق نتایج به صورت زیر به دست می‌آید:

Equation: UNTITLED - Workfile: VNO: Untitled				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: IP				
Method: Least Squares				
Date: 01/30/11 Time: 18:48				
Sample (adjusted): 1346 1380				
Included observations: 36 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-28339.87	12821.01	-2.246372	0.0323
Y	0.393698	0.109818	3.584941	0.0012
R	-2833.283	1208.771	-2.343837	0.0259
D57	22437.89	27178.52	0.825574	0.4156
D57*Y	-0.147861	0.153192	-0.963898	0.3428
D57*R	1105.481	4931.474	0.224158	0.8241
R-squared	0.865818	Mean dependent var	25513.35	
Adjusted R-squared	0.810121	S.D. dependent var	13257.30	
S.E. of regression	8277.898	Akaike info criterion	21.03158	
Sum squared resid	2.06E+09	Schwarz criterion	21.29550	
Log likelihood	-372.5884	Hannan-Quinn criter	21.12368	
F-statistic	11.95430	Durbin-Watson stat	1.447742	
Prob(F-statistic)	0.000002			

ملاحظه می‌شود که هیچ یک از ضرایب مربوط به متغیرهای مجازی، معنی‌دار نیستند و لذا ثبات ضرایب رد نمی‌شود. بدین ترتیب نتایج حاصل از روش چاو و روش متغیرهای مجازی یکسان می‌باشد.

۶-۲ خطای اندازه‌گیری متغیرها

یکی از مشکلاتی که در عمل با آن مواجه می‌شویم، خطای اندازه‌گیری است. به هر دلیلی ممکن است داده‌های گردآوری شده دارای خطا باشند. این خطا می‌تواند هم در مورد متغیر وابسته و هم متغیرهای توضیحی باشد.

ابتدا این بحث را برای متغیرهای توضیحی بررسی می‌کنیم. فرض کنید که مقادیر واقعی متغیر توضیحی برابر با X^* باشد. در این صورت مدل زیر را داریم:

$$Y_i = \alpha + \beta X_i^* + u_i \quad (6-50)$$

اما مقدار واقعی X (یعنی X^*) قابل دسترس نمی‌باشد و لذا از X استفاده می‌کنیم. فرض کنید که بین X و X^* رابطه زیر برقرار باشد:

$$X_t = X_t^* + \varepsilon_t \quad (6-51)$$

بنابراین X_t دارای خطا است که آن را با ε_t نشان می‌دهیم. اما فرض می‌شود که ε_t یک متغیر تصادفی با میانگین صفر و واریانس σ_ε^2 است. با جایگذاری (6-51) در (6-50) خواهیم داشت:

$$Y_t = \alpha + \beta X_t + (u_t - \beta \varepsilon_t) \quad (6-52)$$

$$= \alpha + \beta X_t + v_t, \quad v_t = u_t - \beta \varepsilon_t$$

در اینجا جمله خطا v_t است که مستقل از متغیر توضیحی نیست، زیرا:

$$\text{cov}(v_t, X_t) = E[(v_t - E v_t)(X_t - E X_t)] = E(v_t \varepsilon_t) = \text{cov}(v_t, \varepsilon_t)$$

زیرا $E(\varepsilon_t) = E(v_t) = 0$ و $E(X_t) = E(X_t^*) + E(\varepsilon_t) = X_t^*$ است. حال به جای v_t قرار داده و بقیه محاسبات را انجام می‌دهیم:

$$\begin{aligned} \text{cov}(X_t, v_t) &= E(v_t \varepsilon_t) = E((u_t - \beta \varepsilon_t) \varepsilon_t) \\ &= E(u_t \varepsilon_t) - \beta E(\varepsilon_t^2) = 0 - \beta \sigma_\varepsilon^2 = -\beta \sigma_\varepsilon^2 \end{aligned} \quad (6-53)$$

$E(u_t \varepsilon_t) = 0$ است، زیرا u_t و ε_t مستقل‌اند.

حال تخمین β را از مدل (6-52) به صورت زیر می‌نویسیم و از معادله (6-50) که مقدار

واقعی Y_t را توصیف می‌کند قرار می‌دهیم:

$$\begin{aligned} \hat{\beta} &= \frac{\sum x_t y_t}{\sum x_t^2} = \frac{\sum x_t Y_t}{\sum x_t^2} = \frac{\sum x_t (\alpha + \beta X_t^* + u_t)}{\sum x_t^2} \\ \hat{\beta} &= \frac{\beta \sum x_t X_t^* + \sum x_t u_t}{\sum x_t^2} = \frac{\beta \sum x_t x_t^* + \sum x_t (u_t - \bar{u})}{\sum x_t^2} \end{aligned}$$

به جای x_t از (6-51) مقدار $x_t^* + (\varepsilon_t - \bar{\varepsilon})$ را قرار می‌دهیم:

$$\hat{\beta} = \frac{\beta \sum (x_t^* + (\varepsilon_t - \bar{\varepsilon})) x_t^* + \sum (x_t^* + (\varepsilon_t - \bar{\varepsilon})) (u_t - \bar{u})}{\sum (x_t^* + (\varepsilon_t - \bar{\varepsilon}))^2}$$

با ساده نمودن عبارت فوق و محاسبه حد احتمال (plim) آن خواهیم داشت:

$$\text{plim } \hat{\beta} = \frac{\beta \sigma_{x^*}^2}{\sigma_{x^*}^2 + \sigma_{\varepsilon}^2} = \beta \frac{1}{1 + \frac{\sigma_{\varepsilon}^2}{\sigma_{x^*}^2}} < \beta \quad (6-54)$$

که $\text{plim } \frac{\sum x_t^*}{n} = \sigma_{x^*}^2$ و $\text{plim } \frac{\sum (\varepsilon_t - \bar{\varepsilon})^2}{n} = \sigma_{\varepsilon}^2$ و برای سایر جملات برابر یا صفر می‌باشد، زیرا $\text{cov}(x^*, \varepsilon) = \text{cov}(x^*, u) = \text{cov}(u, \varepsilon) = 0$ است. بنابراین حتی اگر حجم نمونه نیز افزایش یابد، تورش $\hat{\beta}$ از بین نخواهد رفت. با توجه به اینکه $\frac{1}{1 + \sigma_{\varepsilon}^2 / \sigma_{x^*}^2}$ کوچکتر از ۱ است، لذا $\hat{\beta}$ کمتر از حد واقعی، برآورد می‌گردد.

اکنون حالتی را بررسی می‌کنیم که خطای اندازه‌گیری مربوط به متغیر وابسته باشد. در این صورت مدل واقعی به صورت زیر می‌باشد:

$$Y_t^* = \alpha + \beta X_t + u_t \quad (6-55)$$

Y_t^* مقادیر واقعی Y است، اما به جای آن، Y_t را استفاده می‌کنیم که دارای خطا می‌باشد:

$$Y_t = Y_t^* + z_t \quad (6-56)$$

که z_t خطای اندازه‌گیری را نشان می‌دهد. حال در معادله (۶-۳۸) به جای Y_t^* از (۶-۵۶) قرار می‌دهیم:

$$\begin{aligned} Y_t - z_t &= \alpha + \beta X_t + u_t \Rightarrow Y_t = \alpha + \beta X_t + (u_t + z_t) \\ Y_t &= \alpha + \beta X_t + w_t, \quad w_t = u_t + z_t \end{aligned} \quad (6-57)$$

تخمین β برای مدل (۶-۵۷) عبارت است از:

$$\hat{\beta} = \frac{\sum x_t y_t}{\sum x_t^2} = \frac{\sum x_t Y_t}{\sum x_t^2}$$

به جای Y_t از مدل (۶-۵۷) قرار می‌دهیم:

$$\hat{\beta} = \frac{\sum x_t [\alpha + \beta X_t + w_t]}{\sum x_t^2} = \beta + \frac{\sum x_t w_t}{\sum x_t^2} \Rightarrow E(\hat{\beta}) = \beta$$

بنابراین، تخمین‌زننده OLS همچنان بدون تورش است.

همان‌طور که در رگرسیون یک متغیره ثابت شد، واریانس $\hat{\beta}$ برابر است با:

$$\text{var}(\hat{\beta}) = \frac{\sigma_w^2}{\sum x_t^2} \quad (6-58)$$

اما با توجه به $w_t = u_t + z_t$ و با توجه به استقلال u_t و z_t ، رابطه $\sigma_w^2 = \sigma_u^2 + \sigma_z^2$ برقرار است:

$$\text{var}(\hat{\beta}) = \frac{\sigma_u^2 + \sigma_z^2}{\sum x_i^2} \quad (9-59)$$

لذا واضح است که خطای اندازه‌گیری در متغیر وابسته باعث افزایش واریانس تخمین‌زننده OLS می‌شود، اما نمی‌تواند موجب تورش شود، زیرا $E(\hat{\beta}) = \beta$ می‌باشد.

۹-۶ علیت

علیت یکی از مسائل اساسی در بررسی رابطه بین متغیرهای اقتصادی است. تعیین جهت علیت برای متغیرهایی مورد استفاده قرار می‌گیرد که مبانی نظری صریحی در مورد آنها وجود ندارد. یکی از مثال‌های معروف در اقتصاد که مورد مجادله می‌باشد مربوط به رابطه بین رشد تولید ناخالص ملی (Y) و رشد پول (X) است. سؤال این است که آیا رشد پول موجب رشد تولید ناخالص ملی می‌شود یا اینکه ابتدا تولید ناخالص ملی افزایش می‌یابد و سپس موجب افزایش نیاز به پول می‌گردد و به دنبال آن بانک مرکزی حجم پول را افزایش می‌دهد.

روش مرسوم برای بررسی علیت، معروف به آزمون علیت گرانجر^۱ است. در این روش معادلات زیر مورد بررسی قرار می‌گیرند:

$$Y_t = \sum_{i=1}^n \alpha_i X_{t-i} + \sum_{j=1}^n \beta_j Y_{t-j} + u_t \quad (9-83)$$

$$X_t = \sum_{i=1}^n a_i X_{t-i} + \sum_{j=1}^n b_j Y_{t-j} + v_t \quad (9-84)$$

بر اساس معادلات فوق می‌توان بدین صورت بحث نمود که:

الف) اگر $\sum \alpha_i \neq 0$ و $\sum b_j = 0$ بوده و از نظر آماری معنی‌دار باشند، در این صورت علیت از X به Y است.

ب) اگر $\sum \alpha_i = 0$ و $\sum b_j \neq 0$ باشد در این صورت علیت از Y به X است.

ج) اگر $\sum \alpha_i \neq 0$ و $\sum b_j \neq 0$ باشد، در این صورت علیت دو طرفه است.

¹ Granger

د) اگر $\sum \alpha_i = 0$ و $\sum b_i = 0$ باشد، این دو متغیر مستقل‌اند و رابطه‌ای با هم ندارند. هر یک از این فرضیه‌ها را می‌توان با آماره F که قبلاً برای مقایسه رگرسیون‌های مقید و غیرمقید معرفی گردید، آزمون نمود. هر یک از فرضیه‌های فوق بیانگر اعمال یک قید روی ضرایب معادله موردنظر است که با آماره F قابل آزمون است.

آزمون علّیت گرانجر در Eviews

فایل: data5

برای آزمون علّیت در Eviews به صورت زیر عمل می‌کنیم:

Quick → Group Statistics → Granger Causality Test

با انتخاب مسیر فوق، پنجره‌ای با عنوان Series List باز می‌شود که در آن نام متغیرهای مورد نظر را وارد می‌کنیم.



با انتخاب OK پنجره کوچکی با عنوان Lag Specification باز می‌شود که در آن تعداد وقفه‌هایی را که لازم است به متغیرها بدهیم وارد می‌کنیم.



در اینجا لازم است که وقفه‌های مختلف را بررسی کنیم، زیرا ممکن است بین دو متغیر، در وقفه‌های کوتاه رابطه علّیت وجود نداشته باشد، ولی با وقفه‌های طولانی‌تر بین آنها رابطه علّیت به وجود آید. به عنوان مثال نتایج آزمون علّیت برای دو متغیر X و Y به صورت زیر داده می‌شود:

د) اگر $\sum \alpha_i = 0$ و $\sum b_i = 0$ باشد، این دو متغیر مستقل‌اند و رابطه‌ای با هم ندارند. هر یک از این فرضیه‌ها را می‌توان با آماره F که قبلاً برای مقایسه رگرسیون‌های مقید و غیرمقید معرفی گردید، آزمون نمود. هر یک از فرضیه‌های فوق بیانگر اعمال یک قید روی ضرایب معادله موردنظر است که با آماره F قابل آزمون است.

آزمون علّیت گرانجر در Eviews

فایل: data5

برای آزمون علّیت در Eviews به صورت زیر عمل می‌کنیم:

Quick → Group Statistics → Granger Causality Test

با انتخاب مسیر فوق، پنجره‌ای با عنوان Series List باز می‌شود که در آن نام متغیرهای مورد نظر را وارد می‌کنیم.



با انتخاب OK پنجره کوچکی با عنوان Lag Specification باز می‌شود که در آن تعداد وقفه‌هایی را که لازم است به متغیرها بدهیم وارد می‌کنیم.



در اینجا لازم است که وقفه‌های مختلف را بررسی کنیم، زیرا ممکن است بین دو متغیر، در وقفه‌های کوتاه رابطه علّیت وجود نداشته باشد، ولی با وقفه‌های طولانی‌تر بین آنها رابطه علّیت به وجود آید. به عنوان مثال نتایج آزمون علّیت برای دو متغیر X و Y به صورت زیر داده می‌شود:

[6] Group: UNTITLED Workfile: UNTITLED			
View	Proc	Object	Print Name Freeze Sample Sheet Stats Spec
Pairwise Granger Causality Tests			
Date: 12/26/13 Time: 14.20			
Sample: 1353 1388			
Lags: 9			
Null Hypothesis	Obs	F-Statistic	Prob
X1 does not Granger Cause Y1	23	8.64369	0.0419
Y1 does not Granger Cause X1		40.5855	0.0014

در جدول فوق، عبارت «X does not Granger Cause Y» بیانگر این فرضیه است که «X علت Y نیست». این فرضیه معادل با این است که در معادلات (1-14) و (1-15)، $\sum \alpha_i = 0$ و $\sum b_j \neq 0$ می‌باشد. حال برای این فرضیه، اگر مقدار F بزرگتر از F جدول باشد، یا مقدار احتمال آن که در ستون آخر داده می‌شود، کوچکتر از ۰/۰۵ باشد، در این صورت فرضیه فوق رد می‌شود. این بدان معنا است که «X علت Y است». بنابراین در مثال فوق، با توجه به مقادیر F و احتمال‌های آن، «X علت Y است» و همچنین «Y علت X است». پس رابطه علیت دو طرفه است.

مسائل

۱- محاسبات زیر را داریم:

$$X'X = \begin{bmatrix} 20 & 10 \\ 10 & 30 \end{bmatrix} \quad X'y = \begin{bmatrix} 30 \\ 40 \end{bmatrix} \quad \sum_i y_i^2 = 70$$

الف) رگرسیون Y روی X را برآورد کنید.

ب) یک مشاهده جدید با $X=2$ و $Y=4$ به دست آمده است، آزمون پیش‌بینی چاو را برای

ثبات ضرایب انجام دهید.

۲- یک رگرسیون سه متغیره با استفاده از داده‌های دوره ۸۶-۱۳۶۸ برآورد شده است:

$$\hat{Y}_t = 2/2 + 0/104X_{1t} - 3/48X_{2t} + 0/34X_{3t}$$

مجموع تغییرات توضیح داده شده ۱۰۹/۶ و مجموع تغییرات توضیح داده نشده ۱۸/۴۸ بود.

وقتی رگرسیون را با اضافه نمودن سه متغیر مجازی فصلی برآورد نمودیم مجموع تغییرات توضیح

داده شده به ۱۱۴/۸ افزایش یافت. آیا اثرات فصلی معنادار است.

۳- معادله رگرسیون $Y_i = \alpha + \beta X_i + u_i$ با یک نمونه ۲۰ تایی از یک منطقه شهری و یک

نمونه ۱۰ تایی از یک منطقه روستایی در دست بررسی است. مقادیر زیر برای این مناطق حساب

شده است:

$$\begin{aligned} X'X &= \begin{bmatrix} 20 & 20 \\ 20 & 25 \end{bmatrix} & X'y &= \begin{bmatrix} 10 \\ 20 \end{bmatrix} & \sum y_i^2 &= 30 & \text{شهری} \\ X'X &= \begin{bmatrix} 10 & 10 \\ 10 & 20 \end{bmatrix} & X'y &= \begin{bmatrix} 8 \\ 20 \end{bmatrix} & \sum y_i^2 &= 24 & \text{روستایی} \end{aligned}$$

آیا برای هر دو منطقه رابطه یکسانی وجود دارد.

۴- در مسئله ۳ موارد زیر را بررسی کنید:

الف) فقط عرض از مبدأ متفاوت باشد.

ب) فقط شیب متفاوت باشد.

۵- در مورد مفهوم همخطی در مدل‌های رگرسیون، به سؤالات زیر پاسخ دهید.

الف) مفهوم همخطی را توضیح دهید.

ب) نحوه شناسایی همخطی را توضیح دهید.

ج) چه راه کارهایی را برای رفع همخطی پیشنهاد می‌دهید.

۶- در مدل $Y_i = \beta_1 + \beta_2 X_i + \beta_3 Z_i + u_i$ اگر متغیر Z_i حذف شود، ثابت کنید که موجب

تورش β_1 می‌شود. همچنین نشان دهید که مقدار تورش بستگی به ضریب همبستگی X و Z دارد.

۷- در مسئله ۱ فصل اول، آزمون حذف متغیر Z را انجام دهید.

۸- در مسئله ۱ فصل اول، آزمون متغیر زائد را برای Z انجام دهید.

۹- مراحل آزمون فرضیه را برای مقایسه دو رگرسیون $X_i = \beta_1 + \beta_2 X_i + \beta_3 Z_i + u_i$ و $Y_i = \beta_1 + \beta_2 X_i + v_i$ تشریح کنید.

۱۰- در مسئله ۱ فصل اول، با استفاده از متغیرهای مجازی بررسی کنید که آیا وقتی مقادیر Z منفی است، اثر آن متفاوت از حالتی است که مقادیر Z مثبت است؟


۱۱- در یک رگرسیون پویا میانگین وقفه و میانه وقفه به ترتیب برابر با $4/5$ و 3 به دست آمده است. مفهوم این مقادیر را به طور دقیق توضیح دهید.

۱۲- در مسئله ۱ فصل اول، آزمون علیت را برای متغیرهای X ، Y و Z انجام دهید.

۱۳- در فرضیه انتظارات تطبیقی و فرضیه تعدیلات جزئی، جملات خطای رگرسیون چه تفاوتی دارند؟

۱۴- در معادله $Y_i = \alpha + \beta X_i + u_i$ اگر هم X و هم Y دارای خطای اندازه‌گیری باشند، چه تأثیری بر تخمین‌زننده β دارد؟

۱۵- فرض کنید نمودار مشاهدات X و Y به‌صورت زیر باشد.



بعد از برآورد معادله $Y_i = \alpha + \beta X_i + u_i$ معلوم شد که β معنادار نیست. با حذف مشاهده A و برآورد مجدد مدل، β معنادار شد. دلیل آن را بیان کنید.


۱۶- ثابت کنید که اگر متغیر Z_i از معادله $Y_i = \alpha + \beta X_i + \gamma Z_i + u_i$ حذف شود و Z_i هیچ همبستگی یا X_i نداشته باشد، آنگاه تخمین ضریب X_i در معادله $Y_i = \alpha + \beta X_i + u_i$ بدون تورش خواهد بود.

۱۷- اگر Z_i از معادله $Y_i = \alpha + \beta X_i + \gamma Z_i + u_i$ حذف شود و Z_i با X_i همبستگی نداشته باشد، آیا تخمین عرضه از مبدأ تغییر خواهد کرد یا نه؟ چرا؟

۱۸- در آزمون چاو اگر دوتقطه تغییر ساختاری وجود داشته باشد، مراحل انجام آزمون را نوشته و تابع F را تشکیل دهید.

۱۹- ثابت کنید که در معادله $Y_i = \alpha + \beta X_i + u_i$ اگر α را حذف و معادله $Y_i = \beta X_i + u_i$ را برآورد کنیم، آنگاه برآورد β دچار تورش خواهد شد. مقدار تورش به چه چیزی بستگی دارد؟

۲۰- مشاهدات X و Y به‌صورت نمودار زیر است:



الف) با استفاده از متغیرهای مجازی، معادله‌ای را برای توصیف نمودار فوق طرح کنید.

ب) در چه صورتی می‌توان آزمون نقطه شکست چاو را برای نمودار فوق به کار برد.

۲۱- معادله $Y_i^* = \alpha + \beta X_i^* + u_i$ را داریم که Y^* و X^* مقادیر واقعی هستند ولی به جای آن از $Y_i = \alpha + \beta X_i + u_i$ استفاده می‌شود که $Y_i = Y_i^* + w_i$ و $X_i = X_i^* + v_i$ می‌باشند. w_i و v_i خطای اندازه‌گیری هستند که میانگین صفر و واریانس σ_w^2 و σ_v^2 دارند. ثابت کنید که تخمین‌زننده OLS برای β ناسازگار است.

۲۲- به جای مدل $Y_i = \beta_1 + \beta_2 X_{1i} + \beta_3 X_{2i} + u_i$ معادلات زیر برآورد می‌شود:

$$Y_i = \alpha_1 + \alpha_2 X_{1i} + \varepsilon_i$$

$$X_{2i} = \alpha_3 + \alpha_4 X_{1i} + \varepsilon_i$$

الف) رابطه بین β_1 با α_1 و α_2 چیست؟

ب) رابطه بین β_2 با α_2 و α_4 چیست؟

ج) واریانس $\hat{\beta}_2$ و $\hat{\alpha}_4$ را مقایسه کنید.

۲۳- ثابت کنید که اگر در معادله $Y_i = \alpha + \beta X_i + u_i$ ، متغیر X_i در معرض خطای اندازه‌گیری باشد، موجب تورش در تخمین β خواهد شد.

۲۴- ثابت کنید که اگر در معادله $Y_i = \alpha + \beta X_i + \gamma Z_i + u_i$ به اشتباه Z_i حذف شود و مدل $Y_i = a + bX_i + \varepsilon_i$ برآورد گردد (حذف متغیر مهم) آنگاه تخمین ضریب X_i دارای تورش (اریب) خواهد بود.

ضمیمه فصل ۶: آزمون‌های خاص در Stata

نایل	آزمون حذف متغیرهای مهم در Stata
برای انجام این آزمون می‌توان از آزمون F برای مقایسه دو مدل غیر مقید و مقید استفاده نمود. مراحل آزمون عبارت است از:	۱- مدل غیر مقید:
reg y1 x1 x2	الف) مدل غیر مقید را تخمین می‌زنیم:
scalar rssu=e(rss)	ب) مجموع مجذور خطاهای غیر مقید را با فرمان زیر ذخیره می‌کنیم:
scalar dfu=e(df_r)	ج) درجه آزادی غیر مقید را با فرمان زیر ذخیره می‌کنیم:
reg y1 x1	۲- مدل مقید (متغیر X_2 را حذف می‌کنیم): الف) مدل مقید را تخمین می‌زنیم:

ب) مجموع مجذور خطاهای مقید را با فرمان زیر ذخیره می‌کنیم:

```
scalar rssr=e(rss)
```

ج) درجه آزادی مقید را با فرمان زیر ذخیره می‌کنیم:

```
scalar dfr=e(df_r)
```

۳- آماره F را با فرمان زیر حساب می‌کنیم:

```
f=dfu/(dfr-dfu)*(rssr-rssu)/rssu
```

علاوه بر این، می‌توان مقدار احتمالا ($pvalue$) را با فرمان زیر حساب نمود:

```
scalar pvalue=F(dfr-dfu,dfu,f)
```

۴- مقادیر محاسبه شده را می‌توان با فرمان زیر مشاهده نمود (البته مشاهده F و $pvalue$ کفایت می‌کند):

```
Scalar list rssu rssr dfu dfr f pvalue
```

مقدار F را با عدد بحرانی مقایسه کرده و نتیجه‌گیری می‌کنیم. اگر مقدار F در ناحیه بحرانی قرار بگیرد نشان می‌دهد که متغیر حذف شده، مهم بوده است. از طرف دیگر اگر مقدار احتمال از 0.05 کوچکتر باشد، نشان می‌دهد که مقدار F در ناحیه بحرانی قرار دارد و لذا متغیر حذف شده مهم بوده است. به عنوان مثال نتایج این محاسبات عبارت است از:

```
. scalar list rssr rssu dfr dfu f pvalue
      rssr = .80476775
      rssu = .10019204
      dfr =      30
      dfu =      29
      f = 203.93533
      pvalue = 1.185e-14
```

چون مقدار $F=203.93$ در ناحیه بحرانی قرار دارد (زیرا احتمال کوچکتر از 0.05 است)، لذا متغیر حذف شده X_2 مهم بوده است.

آزمون متغیرهای زائد

بدین منظور مراحل زیر را انجام می‌دهیم:

۱- معادله مورد نظر را تخمین می‌زنیم:

```
reg y1 x1 x2
```

۲- فرمان زیر را برای آزمون معادلات بودن X_2 انجام می‌دهیم:

```
test x2=0
```

۳- نتیجه آزمون به صورت زیر به‌دست می‌آید:

```
. test x2=0

( 1)  x2 = 0

      F( 1,      29) = 203.94
      Prob > F =      0.0000
```

چون مقدار $F=203.93$ در ناحیه بحرانی قرار دارد (زیرا احتمال کوچکتر از 0.05 است)، لذا متغیر زائد X_2 نیست.

آزمون جاو در Stata

مراحل آزمون جاو به‌صورت زیر می‌باشد:

۱- ابتدا زمان تغییر ساختاری را معلوم کنید (در این مثال سال ۱۳۷۰ می‌باشد).

۲- یک متغیر مجازی با فرمان زیر ایجاد کنید که برای سال‌های قبل از ۱۳۷۰ برابر با ۱ می‌باشد:

```
gen d=(t>=1370)
```

۳- رگرسیون دوره اول را برآورد کرده و سپس مجموع مجذور خطاها و درجه آزادی را ذخیره کنید:

```
reg y1 x1
```

```
scalar rss1=e(rss)
```

```
scalar df1=e(df_r)
```

۴- رگرسیون دوره دوم را برآورد کرده و سپس مجموع مجذور خطاها و درجه آزادی را ذخیره کنید:

```
reg y1 x1
```

```
scalar rss2=e(rss)
```

```
scalar df2=e(df_r)
```

۵- مجموع مجذور خطاهای دو دوره و مجموع درجه آزادی‌ها را حساب کنید:

```
scalar rssu=rss1+rss2
```

```
scalar dfu=df1+df2
```

۶- رگرسیون کل دوره را برآورد کرده و سپس مجموع مجذور خطاها و درجه آزادی را ذخیره کنید:

```
reg y1 x1
```

```
scalar rssr=e(rss)
```

```
scalar dfr=e(df_r)
```

۷- آماره F را و احتمال مربوطه را حساب می‌کنیم:

```
f=dfu/(dfr-dfu)*(rssr-rssu)/rssu
```

```
scalar pvalue=F(dfr-dfu, dfu, f)
```

۸- مقادیر محاسبه شده را می‌توان با فرمان زیر مشاهده نمود:

```
scalar list f pvalue
```

مقدار F را با عدد بحرانی مقایسه کرده و نتیجه‌گیری می‌کنیم. اگر مقدار F در ناحیه بحرانی قرار بگیرد نشان می‌دهد که تغییر ساختاری رخ داده است و ضرایب در این دو دوره متفاوت هستند.

آزمون علیت گرانجر در Stata

آزمون علیت گرانجر را می‌توان با استفاده از مدل‌های خودرگرسیون برداری (VAR) انجام داد اما چون این مدل‌ها در فصل ۱۸ بررسی می‌شوند لذا در اینجا از روش ساده‌تری استفاده می‌کنیم. فرض کنید که رابطه علین بین دو متغیر y_1 و y_2 را می‌خواهیم با پنج وقفه بررسی کنیم.

ابتدا بررسی می‌کنیم که آیا y_2 علت y_1 هست یا نه. بدین منظور معادله زیر را برآورد می‌کنیم:

```
reg y1 l(1/5).y1 l(1/5).y2
```

حال آزمون صفر بودن ضرایب y_2 را به فرمان زیر انجام می‌دهیم:

```
test (l1.y2=l2.y2-l3.y2-l4.y2=l5.y2=0)
```

نتیجه آزمون عبارت است از:

```
. test (l1.y2=l2.y2-l3.y2-l4.y2=l5.y2=0)
```

```
( 1)  L.y2 - L2.y2 = 0
( 2)  L.y2 - L3.y2 = 0
( 3)  L.y2 - L4.y2 = 0
( 4)  L.y2 - L5.y2 = 0
( 5)  L.y2 = 0
```

```
F( 5, 16) = 0.98
Prob > F = 0.4604
```

چون مقدار $F=0.98$ در ناحیه بحرانی قرار ندارد (زیرا احتمال بزرگتر از ۰/۰۵ است)، لذا $y2$ علت $y1$ نیست. مشابه بحث فوق بررسی می‌کنیم که آیا $y1$ علت $y2$ هست یا نه. بدین منظور معادله زیر را برآورد می‌کنیم:

```
reg y2 l(1/5).y1 l(1/5).y2
```

حال آزمون صفر بودن ضرایب $y1$ را به فرمان زیر انجام می‌دهیم:

```
test (l1.y1=l2.y1-l3.y1-l4.y1=l5.y1=0)
```

نتیجه آزمون عبارت است از:

```
. test (l1.y1=l2.y1-l3.y1-l4.y1=l5.y1=0)
```

```
( 1)  L.y1 - L2.y1 = 0
( 2)  L.y1 - L3.y1 = 0
( 3)  L.y1 - L4.y1 = 0
( 4)  L.y1 - L5.y1 = 0
( 5)  L.y1 = 0
```

```
F( 5, 16) = 0.20
Prob > F = 0.9566
```

چون مقدار $F=0.20$ در ناحیه بحرانی قرار ندارد (زیرا احتمال بزرگتر از ۰/۰۵ است)، لذا $y1$ علت $y2$ نیست.

ضمیمه
جداول آماری

مقادیر توزیع $t_{\alpha,n}$

n	0.25	0.1	0.05	0.025	0.01	0.005
1	1.000	3.078	6.314	12.706	31.821	63.657
2	.816	1.886	2.920	4.303	6.965	9.925
3	.765	1.638	2.353	3.182	4.541	5.841
4	.741	1.533	2.132	2.776	3.747	4.604
5	.727	1.476	2.015	2.571	3.365	4.032
6	.718	1.440	1.943	2.447	3.143	3.707
7	.711	1.415	1.895	2.365	2.998	3.499
8	.706	1.397	1.860	2.306	2.896	3.355
9	.703	1.383	1.833	2.262	2.821	3.250
10	.700	1.372	1.812	2.228	2.764	3.169
11	.697	1.363	1.796	2.201	2.718	3.106
12	.695	1.356	1.782	2.179	2.681	3.055
13	.694	1.350	1.771	2.160	2.650	3.012
14	.692	1.345	1.761	2.145	2.624	2.977
15	.691	1.341	1.753	2.131	2.602	2.947
16	.690	1.337	1.746	2.120	2.583	2.921
17	.689	1.333	1.740	2.110	2.567	2.898
18	.688	1.330	1.734	2.101	2.552	2.878
19	.688	1.328	1.729	2.093	2.539	2.861
20	.687	1.325	1.725	2.086	2.528	2.845
21	.686	1.323	1.721	2.080	2.518	2.831
22	.686	1.321	1.717	2.074	2.508	2.819
23	.685	1.319	1.714	2.069	2.500	2.807
24	.685	1.318	1.711	2.064	2.492	2.797
25	.684	1.316	1.708	2.060	2.485	2.787
26	.684	1.315	1.706	2.056	2.479	2.779
27	.684	1.314	1.703	2.052	2.473	2.771
28	.683	1.313	1.701	2.048	2.467	2.763
29	.683	1.311	1.699	2.045	2.462	2.756
30	.683	1.310	1.697	2.042	2.457	2.750
35	.682	1.306	1.690	2.030	2.438	2.724
40	.681	1.303	1.684	2.021	2.423	2.704
45	.680	1.301	1.679	2.014	2.412	2.690
50	.679	1.299	1.676	2.009	2.403	2.678
60	.679	1.296	1.671	2.000	2.390	2.660
70	.678	1.294	1.667	1.994	2.381	2.648
80	.678	1.292	1.664	1.990	2.374	2.639
90	.677	1.291	1.662	1.987	2.368	2.632
100	.677	1.290	1.660	1.984	2.364	2.626
∞	.674	1.282	1.645	1.960	2.326	2.576

مقادیر توزیع $\chi^2_{\alpha, n}$

n	.005	.010	.025	.050	.100	.250	.500	.750	.900	.950	.975	.990	.995
1	.00004	.0002	.001	.004	.02	.10	.45	1.32	2.71	3.84	5.02	6.63	7.88
2	.01	.02	.05	.10	.21	.58	1.39	2.77	4.61	5.99	7.38	9.21	10.60
3	.07	.11	.22	.35	.58	1.21	2.37	4.11	6.25	7.81	9.35	11.34	12.84
4	.21	.30	.48	.71	1.06	1.92	3.36	5.39	7.78	9.49	11.14	13.28	14.86
5	.41	.55	.83	1.15	1.61	2.67	4.35	6.63	9.24	11.07	12.83	15.09	16.75
6	.68	.87	1.24	1.64	2.20	3.45	5.35	7.84	10.64	12.59	14.45	16.81	18.55
7	.99	1.24	1.69	2.17	2.83	4.25	6.35	9.04	12.02	14.07	16.01	18.48	20.28
8	1.34	1.65	2.18	2.73	3.49	5.07	7.34	10.22	13.36	15.51	17.53	20.09	21.95
9	1.73	2.09	2.70	3.33	4.17	5.90	8.34	11.39	14.68	16.92	19.02	21.67	23.59
10	2.16	2.56	3.25	3.94	4.87	6.74	9.34	12.55	15.99	18.31	20.48	23.21	25.19
11	2.60	3.05	3.82	4.57	5.58	7.58	10.34	13.70	17.28	19.68	21.92	24.72	26.76
12	3.07	3.57	4.40	5.23	6.30	8.44	11.34	14.85	18.55	21.03	23.34	26.22	28.30
13	3.57	4.11	5.01	5.89	7.04	9.30	12.34	15.98	19.81	22.36	24.74	27.69	29.82
14	4.07	4.66	5.63	6.57	7.79	10.17	13.34	17.12	21.06	23.68	26.12	29.14	31.32
15	4.60	5.23	6.26	7.26	8.55	11.04	14.34	18.25	22.31	25.00	27.49	30.58	32.80
16	5.14	5.81	6.91	7.96	9.31	11.91	15.34	19.37	23.54	26.30	28.85	32.00	34.27
17	5.70	6.41	7.56	8.67	10.09	12.79	16.34	20.49	24.77	27.59	30.19	33.41	35.72
18	6.26	7.01	8.23	9.39	10.86	13.68	17.34	21.60	25.99	28.87	31.53	34.81	37.16
19	6.84	7.63	8.91	10.12	11.65	14.56	18.34	22.72	27.20	30.14	32.85	36.19	38.58
20	7.43	8.26	9.59	10.85	12.44	15.45	19.34	23.83	28.41	31.41	34.17	37.57	40.00
21	8.03	8.90	10.28	11.59	13.24	16.34	20.34	24.93	29.62	32.67	35.48	38.93	41.40
22	8.64	9.54	10.98	12.34	14.04	17.24	21.34	26.04	30.81	33.92	36.78	40.29	42.80
23	9.26	10.20	11.69	13.09	14.85	18.14	22.34	27.14	32.01	35.17	38.08	41.64	44.18
24	9.89	10.86	12.40	13.85	15.66	19.04	23.34	28.24	33.20	36.42	39.36	42.98	45.56
25	10.52	11.52	13.12	14.61	16.47	19.94	24.34	29.34	34.38	37.65	40.65	44.31	46.93
30	13.79	14.95	16.79	18.49	20.60	24.48	29.34	34.80	40.26	43.77	46.98	50.89	53.67
35	17.19	18.51	20.57	22.47	24.80	29.05	34.34	40.22	46.06	49.80	53.20	57.34	60.27
40	20.71	22.16	24.43	26.51	29.05	33.66	39.34	45.62	51.81	55.76	59.34	63.69	66.77
45	24.31	25.90	28.37	30.61	33.35	38.29	44.34	50.98	57.51	61.66	65.41	69.96	73.17
50	27.99	29.71	32.36	34.76	37.69	42.94	49.33	56.33	63.17	67.50	71.42	76.15	79.49

مقادیر توزیع F_{α, n_1, n_2}

درجه آزادی صورت n_1

n_2	1	2	3	4	5	6	7	8	9
1	161.45	199.50	215.71	224.58	230.16	233.99	236.77	238.88	240.54
2	18.51	19.00	19.16	19.25	19.30	19.33	19.35	19.37	19.38
3	10.13	9.55	9.28	9.12	9.01	8.94	8.89	8.85	8.81
4	7.71	6.94	6.59	6.39	6.26	6.16	6.09	6.04	6.00
5	6.61	5.79	5.41	5.19	5.05	4.95	4.88	4.82	4.77
6	5.99	5.14	4.76	4.53	4.39	4.28	4.21	4.15	4.10
7	5.59	4.74	4.35	4.12	3.97	3.87	3.79	3.73	3.68
8	5.32	4.46	4.07	3.84	3.69	3.58	3.50	3.44	3.39
9	5.12	4.26	3.86	3.63	3.48	3.37	3.29	3.23	3.18
10	4.96	4.10	3.71	3.48	3.33	3.22	3.14	3.07	3.02
15	4.54	3.68	3.29	3.06	2.90	2.79	2.71	2.64	2.59
20	4.35	3.49	3.10	2.87	2.71	2.60	2.51	2.45	2.39
25	4.24	3.39	2.99	2.76	2.60	2.49	2.40	2.34	2.28
30	4.17	3.32	2.92	2.69	2.53	2.42	2.33	2.27	2.21
40	4.08	3.23	2.84	2.61	2.45	2.34	2.25	2.18	2.12
50	4.03	3.18	2.79	2.56	2.40	2.29	2.20	2.13	2.07
70	3.98	3.13	2.74	2.50	2.35	2.23	2.14	2.07	2.02
100	3.94	3.09	2.70	2.46	2.31	2.19	2.10	2.03	1.97
∞	3.84	3.00	2.60	2.37	2.21	2.10	2.01	1.94	1.88

n_2	10	12	15	20	30	40	50	60	∞
1	241.88	243.91	245.95	248.01	250.10	251.14	252.20	252.20	254.19
2	19.40	19.41	19.43	19.45	19.46	19.47	19.48	19.48	19.49
3	8.79	8.74	8.70	8.66	8.62	8.59	8.57	8.57	8.53
4	5.96	5.91	5.86	5.80	5.75	5.72	5.69	5.69	5.63
5	4.74	4.68	4.62	4.56	4.50	4.46	4.43	4.43	4.37
6	4.06	4.00	3.94	3.87	3.81	3.77	3.74	3.74	3.67
7	3.64	3.57	3.51	3.44	3.38	3.34	3.30	3.30	3.23
8	3.35	3.28	3.22	3.15	3.08	3.04	3.01	3.01	2.93
9	3.14	3.07	3.01	2.94	2.86	2.83	2.79	2.79	2.71
10	2.98	2.91	2.85	2.77	2.70	2.66	2.62	2.62	2.54
15	2.54	2.48	2.40	2.33	2.25	2.20	2.16	2.16	2.07
20	2.35	2.28	2.20	2.12	2.04	1.99	1.95	1.95	1.85
25	2.24	2.16	2.09	2.01	1.92	1.87	1.82	1.82	1.72
30	2.16	2.09	2.01	1.93	1.84	1.79	1.74	1.74	1.63
40	2.08	2.00	1.92	1.84	1.74	1.69	1.64	1.64	1.52
50	2.03	1.95	1.87	1.78	1.69	1.63	1.58	1.58	1.45
70	1.97	1.89	1.81	1.72	1.62	1.57	1.50	1.50	1.36
100	1.93	1.85	1.77	1.68	1.57	1.52	1.45	1.45	1.30
∞	1.83	1.75	1.67	1.57	1.46	1.39	1.34	1.31	1.30

مقادیر توزیع F_{α, n_1, n_2} درجه آزادی صورت n_1

n_2	1	2	3	4	5	6	7	8	9
1	4052.18	4999.50	5403.35	5624.58	5763.65	5858.99	5928.36	5981.07	6022.47
2	98.50	99.00	99.17	99.25	99.30	99.33	99.36	99.37	99.39
3	34.12	30.82	29.46	28.71	28.24	27.91	27.67	27.49	27.35
4	21.20	18.00	16.69	15.98	15.52	15.21	14.98	14.80	14.66
5	16.26	13.27	12.06	11.39	10.97	10.67	10.46	10.29	10.16
6	13.75	10.92	9.78	9.15	8.75	8.47	8.26	8.10	7.98
7	12.25	9.55	8.45	7.85	7.46	7.19	6.99	6.84	6.72
8	11.26	8.65	7.59	7.01	6.63	6.37	6.18	6.03	5.91
9	10.56	8.02	6.99	6.42	6.06	5.80	5.61	5.47	5.35
10	10.04	7.56	6.55	5.99	5.64	5.39	5.20	5.06	4.94
15	8.68	6.36	5.42	4.89	4.56	4.32	4.14	4.00	3.89
20	8.10	5.85	4.94	4.43	4.10	3.87	3.70	3.56	3.46
25	7.77	5.57	4.68	4.18	3.85	3.63	3.46	3.32	3.22
30	7.56	5.39	4.51	4.02	3.70	3.47	3.30	3.17	3.07
40	7.31	5.18	4.31	3.83	3.51	3.29	3.12	2.99	2.89
50	7.17	5.06	4.20	3.72	3.41	3.19	3.02	2.89	2.78
70	7.01	4.92	4.07	3.60	3.29	3.07	2.91	2.78	2.67
100	6.90	4.82	3.98	3.51	3.21	2.99	2.82	2.69	2.59
∞	6.66	4.63	3.80	3.34	3.04	2.82	2.66	2.53	2.43

n_2	10	12	15	20	30	40	50	60	∞
1	6055.85	6106.32	6157.28	6208.73	6260.65	6286.78	6313.03	6313.03	6362.68
2	99.40	99.42	99.43	99.45	99.47	99.47	99.48	99.48	99.50
3	27.23	27.05	26.87	26.69	26.50	26.41	26.32	26.32	26.14
4	14.55	14.37	14.20	14.02	13.84	13.75	13.65	13.65	13.47
5	10.05	9.89	9.72	9.55	9.38	9.29	9.20	9.20	9.03
6	7.87	7.72	7.56	7.40	7.23	7.14	7.06	7.06	6.89
7	6.62	6.47	6.31	6.16	5.99	5.91	5.82	5.82	5.66
8	5.81	5.67	5.52	5.36	5.20	5.12	5.03	5.03	4.87
9	5.26	5.11	4.96	4.81	4.65	4.57	4.48	4.48	4.32
10	4.85	4.71	4.56	4.41	4.25	4.17	4.08	4.08	3.92
15	3.80	3.67	3.52	3.37	3.21	3.13	3.05	3.05	2.88
20	3.37	3.23	3.09	2.94	2.78	2.69	2.61	2.61	2.43
25	3.13	2.99	2.85	2.70	2.54	2.45	2.36	2.36	2.18
30	2.98	2.84	2.70	2.55	2.39	2.30	2.21	2.21	2.02
40	2.80	2.66	2.52	2.37	2.20	2.11	2.02	2.02	1.82
50	2.70	2.56	2.42	2.27	2.10	2.01	1.91	1.91	1.70
70	2.59	2.45	2.31	2.15	1.98	1.89	1.78	1.78	1.56
100	2.50	2.37	2.22	2.07	1.89	1.80	1.69	1.69	1.45
∞	2.34	2.20	2.06	1.90	1.72	1.61	1.50	1.50	1.16

مقادیر آماره دورین-واتسن (DW)

n	k = 1		k = 2		k = 3		k = 4		k = 5		k = 10		k = 15	
	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU	dL	dU
15	1.08	1.36	.95	1.54	.82	1.75	.69	1.97	.56	2.21				
16	1.10	1.37	.98	1.54	.86	1.73	.74	1.93	.62	2.15	.16	3.30		
17	1.13	1.38	1.02	1.54	.90	1.71	.78	1.90	.67	2.10	.20	3.18		
18	1.16	1.39	1.05	1.53	.93	1.69	.82	1.87	.71	2.06	.24	3.07		
19	1.18	1.40	1.08	1.53	.97	1.68	.86	1.85	.75	2.02	.29	2.97		
20	1.20	1.41	1.10	1.54	1.00	1.68	.90	1.83	.79	1.99	.34	2.89	.06	3.68
21	1.22	1.42	1.13	1.54	1.03	1.67	.93	1.81	.83	1.96	.38	2.81	.09	3.58
22	1.24	1.43	1.15	1.54	1.05	1.66	.96	1.80	.86	1.94	.42	2.73	.12	3.55
23	1.26	1.44	1.17	1.54	1.08	1.66	.99	1.79	.90	1.92	.47	2.67	.15	3.41
24	1.27	1.45	1.19	1.55	1.10	1.66	1.01	1.78	.93	1.90	.51	2.61	.19	3.33
25	1.29	1.45	1.21	1.55	1.12	1.66	1.04	1.77	.95	1.89	.54	2.57	.22	3.25
26	1.30	1.46	1.22	1.55	1.14	1.65	1.06	1.76	.98	1.88	.58	2.51	.26	3.18
27	1.32	1.47	1.24	1.56	1.16	1.65	1.08	1.76	1.01	1.86	.62	2.47	.29	3.11
28	1.33	1.48	1.26	1.56	1.18	1.65	1.10	1.75	1.03	1.85	.65	2.43	.33	3.05
29	1.34	1.48	1.27	1.56	1.20	1.65	1.12	1.74	1.05	1.84	.68	2.40	.36	2.99
30	1.35	1.49	1.28	1.57	1.21	1.65	1.14	1.74	1.07	1.83	.71	2.36	.39	2.94
31	1.36	1.50	1.30	1.57	1.23	1.65	1.16	1.74	1.09	1.83	.74	2.33	.43	2.99
32	1.37	1.50	1.31	1.57	1.24	1.65	1.18	1.73	1.11	1.82	.77	2.31	.46	2.84
33	1.38	1.51	1.32	1.58	1.26	1.65	1.19	1.73	1.13	1.81	.80	2.28	.49	2.80
34	1.39	1.51	1.33	1.58	1.27	1.65	1.21	1.73	1.15	1.81	.82	2.26	.52	2.75
35	1.40	1.52	1.34	1.53	1.28	1.65	1.22	1.73	1.16	1.80	.85	2.24	.55	2.72
36	1.41	1.52	1.35	1.59	1.29	1.65	1.24	1.73	1.18	1.80	.87	2.22	.58	2.68
37	1.42	1.53	1.36	1.59	1.31	1.66	1.25	1.72	1.19	1.80	.89	2.20	.60	2.65
38	1.43	1.54	1.37	1.59	1.32	1.66	1.26	1.72	1.21	1.79	.91	2.18	.63	2.61
39	1.43	1.54	1.38	1.60	1.33	1.66	1.27	1.72	1.22	1.79	.93	2.16	.65	2.59
40	1.44	1.54	1.39	1.60	1.34	1.66	1.29	1.72	1.23	1.79	.95	2.15	.68	2.56
45	1.48	1.57	1.43	1.62	1.38	1.67	1.34	1.72	1.29	1.78	1.04	2.09	.79	2.44
50	1.50	1.59	1.46	1.63	1.42	1.67	1.38	1.72	1.34	1.77	1.11	2.04	.88	2.35
55	1.53	1.60	1.49	1.64	1.45	1.68	1.41	1.72	1.38	1.77	1.17	2.01	.96	2.28
60	1.55	1.62	1.51	1.65	1.48	1.69	1.44	1.73	1.41	1.77	1.22	1.98	1.03	2.23
65	1.57	1.63	1.54	1.66	1.50	1.70	1.47	1.73	1.44	1.77	1.27	1.96	1.09	2.18
70	1.58	1.64	1.55	1.67	1.52	1.70	1.49	1.74	1.46	1.77	1.30	1.95	1.14	2.15
75	1.60	1.65	1.57	1.68	1.54	1.71	1.51	1.74	1.49	1.77	1.34	1.94	1.18	2.12
80	1.61	1.66	1.59	1.69	1.56	1.72	1.53	1.74	1.51	1.77	1.37	1.93	1.22	2.09
85	1.62	1.67	1.60	1.70	1.57	1.72	1.55	1.75	1.52	1.77	1.40	1.92	1.26	2.07
90	1.63	1.68	1.61	1.70	1.59	1.73	1.57	1.75	1.54	1.78	1.42	1.91	1.29	2.06
95	1.64	1.69	1.62	1.71	1.60	1.73	1.58	1.75	1.56	1.78	1.44	1.90	1.32	2.04
100	1.65	1.69	1.63	1.72	1.61	1.74	1.59	1.76	1.57	1.78	1.46	1.90	1.35	2.03

تعداد ضرایب به استثنای عرض از مبدأ $k=$

تعداد مشاهدات $n=$